

**SVEUČILIŠTE U SPLITU
EKONOMSKI FAKULTET**

DIPLOMSKI RAD

**HOMOGENOST HRVATSKIH REGIJA I REGIJA
EU U PROCESU PRIMJENE STRATEGIJE
PAMETNE SPECIJALIZACIJE**

Mentor:

doc. dr. sc. Muštra Vinko

Studentica:

Marija Bliznac

Matični br.: 2130238

Split, rujan, 2018.

SADRŽAJ:

1. UVOD	4
1.1. Problem istraživanja	4
1.2. Predmet istraživanja	5
1.3. Istraživačka pitanja	6
1.4. Ciljevi istraživanja	6
1.5. Metode istraživanja	6
1.6. Doprinos istraživanja	7
2. TEMELJNE ODREDNICE NOVE EUROPSKE STRATEGIJE	9
2.1. Posljedice globalne svjetske krize	9
2.2. Strategija “Europa 2020”	11
2.3. Mjere za ostvarenje ciljeva strategije	14
2.3.1. Kohezijska politika 2014. - 2020.	14
3. STRATEGIJA PAMETNE SPECIJALIZACIJE	17
3.1. Opće značajke strategije	17
3.2. Strategija Pametne Specijalizacije Hrvatske	19
4. REGIONALNI BENCHMARKING U RIS3 PROCESU	24
4.1. Regionalni benchmarking i RIS3	24
4.2. Određivanje varijabli za identifikaciju strukturnih karakteristika	26
4.2.1. Geo demografski indikatori	27
4.2.2. Razina obrazovanja ljudskog kapitala	29
4.2.3. Tehnološka specijalizacija	31
4.2.4. Sektorska struktura	34
4.2.5. Struktura poduzeća	37
4.2.6. Otvorenost	37
4.2.7. Institucije i vrijednosti	37
5. EMPIRIJSKO ISTRAŽIVANJE ODREĐIVANJA HOMOGENOSTI REGIJA	44
5.1. Metodologija istraživanja	44
5.2. Rezultati istraživanja	48
5.2.1. Hijerarhijska klaster metoda	48
5.2.2. Individualni pristup	49
5.2.3. Nehijerarhijska klaster metoda : <i>k</i> - srednjih vrijednosti	54
6. ZAKLJUČAK	56

DODATCI	62
SAŽETAK	64

1.UVOD

1.1.Problem istraživanja

Globalna financijska kriza ostavila je velike posljedice na cjelokupno gospodarstvo EU te izbrisala dosadašnji napredak. Krhak financijski sustav ograničava poduzeća i kućanstva da posuđuju, troše i investiraju, stoga je mogućnost za oporavak i ekonomski razvoj otežana. Izlazak iz krize predstavlja pravi izazov, ali najveći izazov je izbjeći pokušaj povratka na prijašnje stanje koje i prije krize nije bilo zadovoljavajuće u odnosu na njene glavne ekonomske partnere. Suočena sa svim navedenim izazovima europa donosi novu strategiju koja se bazira na pametnom, održivom i uključivom rastu. Glavne smjernice djelovanja su na području inovacija, obrazovanja, održivog i konkurentnijeg gospodarstva te visoke stope zaposlenosti koja donosi ekonomsku, socijalnu i teritorijalnu koheziju (Europska komisija, 2010). Kohezijska politika i strukturni fondovi ključni su mehanizmi za ostvarenje ciljeva strategije "Europa 2020". Jedan od preduvjeta za povlačenje sredstava iz ESI fondova za tematski cilj 1, Jačanje istraživanja, tehnološkog razvoja i inovacija u sklopu *Operativnog programa Konkurentnost i kohezija 2014 –2020*, je i izrada strategije pod nazivom "Strategija pametne specijalizacije", kojom se identificiraju jedinstvene prirodne karakteristike svake zemlje i regije, ističu konkurentne prednosti te određuju područja za buduće inovacije. Kao glavni pokretači ekonomskog razvoja naglašavaju se ulaganja u istraživanje i razvoj, inovacije te ljudski kapital (Europska komisija, 2015).

U ožujku 2016. godine usvojena je "Strategija pametne specijalizacije Republike Hrvatske za razdoblje od 2016.-2020. godine i akcijski plan za provedbu strategije pametne specijalizacije Republike Hrvatske za razdoblje od 2016. do 2017. godine". Prema kriterijima i smjernicama za izradu platforme Strategije pametne specijalizacije (S3) odabrano je pet tematskih prioritetnih područja (TPP) i dvije horizontalne teme. Kao TPP su odabrani: (1) Zdravlje i kvaliteta života, (2) Energija i održivi okoliš, (3) Promet i mobilnost, (4) Sigurnost te (5) Hrana i bioekonomija. U horizontalne teme spadaju (1) Ključne razvojne tehnologije (KET) te (2) Informacijske i komunikacijske tehnologije (ICT) (NN, 2016).

Izrada S3 strategije bio je zahtijevan i složen proces što potvrđuje i vrijeme potrebno za njegovu izradu, a ništa manje se ne očekuje niti kod njegove implementacije. Koncept S3 u hrvatskoj primjenjen je na nacionalnoj razini (NN, 2016). Izbor o primjeni S3 strategije na nacionalnoj ili

regionalnoj razini prepušta se zemljama članicama. Međutim OECD provodi istraživanje na nekoliko regija o upravljanju inovacijske politike i kao rezultat se pokazalo da je određivanje prioriteta javnih ulaganja na istraživanje & razvoj i inovacije intenzivnije na regionalnoj nego na nacionalnoj razini, zato što različite regije imaju različite razine performansi u pogledu pokazatelja povezanih s inovacijama (OECD, 2013). Kako bi se S3 strategijom ostvarili postavljeni ciljevi potrebna je koordinacija na svim razinama vlasti, nacionalnoj, regionalnoj i lokalnoj i usuglašenost svih politika. Navarro i sur. (2014) u svome radu ističu važnost provođenja strategije pametne specijalizacije na temelju benchmarking analize. Ističe da bi najefikasnije rezultate postigli učeći od regija jednakih strukturnih karakteristika, koje ostvaruju bolje performance. Daljnji korak, koji bi trebao rezultirati najefikasnijim i najefektivnijim rezultatom primjene razvojne politike je kopirati politike koje je ta određena regija implementirala. Dakle ovdje se ukazuje na jednu razvojnu politiku za dvije ili više regija jednakih strukturnih karakteristika. Upravo iz razloga jer se “Jednaki trebaju uspoređivati sa jednakima”, te nakon toga primjeniti istu ili sličnu strategiju razvoja. Postavlja se dakle pitanje koliko su regije Jadranska Hrvatska i Kontinentalna Hrvatska slične da bi se na njih mogla provoditi jedinstvena nacionalna Strategija pametne specijalizacije, te postoje li neke regije EU koje posjeduju jednake strukturne karakteristike. Iako je strategija pametne specijalizacije već usvojena, smatra se da bi regionalna benchmarking analiza mogla doprinijeti u svih šest faza prijedloga za konstruiranje strategije pametne specijalizacije: (1) Analiza inovacijskog potencijala (2) Uspostava S3 sustava i upravljanje procesom (3) Razvoj vizije (4) Definiranje prioriteta (5) Definiranje skupa mjera politika, općih smjernica i akcijskog plana (6) Praćenje i evaluacija. Ističe se kako zemlje koje ulažu više u istraživanje i razvoj i inovacije u pravilu se oporavljaju brže od drugih zemalja (Europska komisija, 2013), te su to općenito naprednije i bogatije zemlje. Stoga je jako važno iskoristiti potencijale koje nudi strategija pametne specijalizacije i fondovi EU te otkloniti eventualne mogućnosti razvoja samo jedne regije.

1.2. Predmet istraživanja

Predmet istraživanja polazi od njegovog problema, koliko su regije NUTS 2 razine Jadranska i Kontinentalna Hrvatska slične po svojim strukturnim karakteristikama. Stoga će predmet ovog istraživanja biti usporedba ovih dviju regija na temelju sedam faktora koje su uspostavili Navarro i sur. (2014). To su: geo – demografski, ljudski kapital, tehnološka specijalizacija, ekonomska i industrijska specijalizacija, poslovna struktura, otvorenost te institucije i vrijednosti. Svake od ovih

vrijednosti se sastoji od podvarijabli koje bi u cjelini trebale odrediti strukturno stanje svake od regija. Isto tako će se istom metodom provesti i usporedba, između ostalih regija EU kako bi se odredilo na temelju klaster analize koje od njih po strukturnim karakteristikama odgovaraju regijama Jadranske i Kontinentalne Hrvatske.

1.3.Istraživačka pitanja

Ovim istraživanjem želi se dati odgovor na slijedeća pitanja:

1. Jesu li NUTS II regije u Hrvatskoj, Jadranska i Kontinentalna Hrvatska u dovoljnoj mjeri homogene za provedbu jedinstvene strategije pametne specijalizacije?
2. Postoje li regije u EU koje po svojim strukturnim karakteristikama mogu biti ogledni primjer regijama Jadranske i Kontinentalne Hrvatske za provedbu strategije pametne specijalizacije?

1.4.Ciljevi istraživanja

Cilj ovog istraživanja je utvrđivanje koliko su dvije hrvatske regije NUTS II razine slične da se na njih može primjeniti jedinstvena strategija pametne specijalizacije. U drugome dijelu istraživanja želi se istražiti postoji li neka druga regija u EU, NUTS II razine, koja po svojim strukturnim karakteristikama bolje odgovara hrvatskim regijama Jadranska i Kontinentalan Hrvatska.

1.5.Metode istraživanja

Podatci potrebni za svrhu ovog istraživanja prikupljaju se iz sekundarnih izvora iz baza podataka kao što su OECD, Eurostat, European Social Survey, DZS. Tako prikupljeni podatci se dalje obrađuju u statističkom programu SPSS, gdje se provodi korekcija za outliere, zaobljenost i asimetriju, normalizacija i koncentracija komponenti te dodjeljivanje pondera. Daljnim agregiranjem podataka dobiva se matrica udaljenosti između regija, te klaster ili individualnom analizom dobiva grupa regija sa sličnim strukturnim uvjetima. Na temelju toga se može provesti benchmarking analiza identificiranih regija.

Temeljne metode koje će se koristiti u ovom radu su: induktivna metoda (na temelju pojedinačnih činjenica i saznanja dolazi se do novih činjenica i zakonitosti), deduktivna metoda (razmatranje teme od općeg prema pojedinačnom), metoda analize (istraživanje i objašnjavanje stvarnosti putem raščlanjivanja složenih misaonih tvorevina na jednostavnije djelove te izučavanje svakog dijela za

sebe i u odnosu na druge dijelove) metoda sinteze (spajanje misaonih tvorevina iz jednostavnijih u složenije te povezujući izdvojene elemente u jedinstvenu cjelinu) te odgovarajuća statistička metoda. Istraživanje će se provesti na razini regija Jadranska Hrvatska i Kontinentalna Hrvatska u prvom dijelu a kasnije i usporedba sa ostalim regijama EU kako se bi se odredile one koje dijele slične strukturne karakteristike sa hrvatskim regijama.

1.6. Doprinos istraživanja

Ovim istraživanjem može se doprinijeti u procesu implementacije istraživanja i inovacija u novim i postojećim proizvodnim procesima, koje se navode kao ključne determinante povećanja proizvodnosti gospodarstva, poboljšanje konkurentске prednosti, razine zaposlenosti što u konačnici vodi boljem i stabilnijem hrvatskom gospodarstvu. Usvojena Strategija Pametne Specijalizacije stoga nije sama sebi svrhom, za njezino što efikasnije provođenje korisno je poznavati dubinski specifičnosti svake regije po svim elementima povezanim s inovacijama. Određivanje regija EU sličnih strukturnih karakteristika korisno je jer se smatra da bi usporedba i primjena dobre prakse takvih regija donijela najbolje rezultate.

1.7. Struktura diplomskog rada

Rad je podijeljen u šest dijelova. U prvom poglavlju navest će se sami problem istraživanja i predmet na kojem će se navedeni problem proučavati, definirat će se istraživačka pitanja i ciljevi, metode prikupljanja podataka, doprinos istraživanju i struktura diplomskog rada.

Drugo poglavlje se bavi definiranjem ciljeva nove europske strategije i razlogom njezina uspostavljanja, te način provođenja postavljenih ciljeva.

U trećem poglavlju opisana je strategija pametne specijalizacije, njezin koncept i glavne odrednice gospodarskog rasta. Zatim je opisana strategija pametne specijalizacije RH, gdje su definirana tematska prioritetna područja i način njihovog financiranja.

U četvrtom poglavlju iznose se glavne poveznice između benchmarkinga i strategije pametne specijalizacije i kako bi on mogao pomoći u njezinoj što boljoj provedbi, te identifikacija ključnih varijabli koje određuju strukturne karakteristike određene regije.

Peto poglavlje je empirijski dio istraživanja, o homogenosti hrvatskih regija i regija EU. Ovo poglavlje obuhvaća metodološki dio te analizu rezultata istraživanja. U šestom poglavlju navest će se zaključak u kojem se došlo prilikom istraživanja.

2. TEMELJNE ODREDNICE NOVE EUROPSKE STRATEGIJE

2.1. Posljedice globalne svjetske krize

Postati najdinamičnijom i najkonkurentnijom, na znanju temeljenom ekonomijom do 2010. godine, bio je cilj Europske Unije postavljen 2000. godine Lisabonskom strategijom. Kako bi povećala standard življenja uz zadržavanje svog jedinstvenog socijalnog modela potrebno je povećati produktivnost i kompetitivnost. U glavni fokus djelovanja stavljeni su održiv ekonomski rast s brojnijim i kvalitetnijim radnim mjestima te snažnijom socijalnom kohezijom. Zbog kompleksne strukture u koju se razvila s višestrukim ciljevima i akcijama, nejasnom podjelom odgovornosti i zadatka EU i nacionalne razine, prvobitna Lisabonska strategija je revidirana 2005. godine čime je uspostavljena nova struktura vođenja bazirana na partnerskom pristupu što je imalo pozitivne efekte na kooperaciju u raspodjeli odgovornosti između institucija EU i zemalja članica. U svim zemljama članicama glavni fokus političkih programa postaje: istraživanje i razvoj, ulaganje u ljude/modernizacija tržišta rada, oslobađanje poslovnog potencijala a pogotovo malih i srednjih poduzeća, te klimatske promjene (European commission, 2010b).

Međutim Lisabonska strategija bila je na snazi u vrijeme jako turbulentnih događanja, kako na europskoj tako i na svjetskoj razini. Na kraju prvog desetljeća gospodarsko stanje EU se je našlo u nezavidnom položaju u odnosu na ostatak svijeta. Ciljevi postavljeni za 2010. godinu nisu se realizirali očekivanim rezultatima. Iako je u vremenu prije krize ostvareno povećanje zaposlenosti od 18 milijuna novih radnih mjesta, to nije uvijek značilo i smanjenje stope siromaštva. I dok nije moguće u potpunosti pokazati uzročnu vezu između Lisabonskih reformi i rasta zaposlenosti nesumnjivo je da su one imale važnu ulogu. (Europska komisija, 2010 b). Rastuća globalizacija, starenja stanovništva, tehnološke i ekološke promjene uz postojeće strukturne slabosti, suočavanje s novim izazovima proširenja zemalja članica i članica euro zone te globalna kriza su izazovi s kojima se europa suočava krajem prvog desetljeća. 21. stoljeća. Prema European Commission (2010) u 2009. godini dolazi do pada BDP - a za 4%, smanjenje industrijske proizvodnje na razinu iz 1990.-ih godina te pada zaposlenosti za 10%. Financijska stabilnost je porušena, stoga se kućanstva i poslovni sektor suzdržavaju od potrošnje i ulaganja, prosječni deficit javnog sektora je došao na razinu 7% BDP-a a javni dug na 80% BDP-a .

Kriza je izbrisala dosadašnji napredak te ukazala na temeljne slabosti europske ekonomije. Zbog razlika u poslovnoj strukturi, nižim ulaganjima u istraživanje i razvoj te inovacije, nedovoljne upotrebe informacijske i komunikacijske tehnologije EU se suočava sa nižim razinama produktivnosti i sukladno tome nižim stopama rasta u odnosu na ostatak svijeta. Stope zaposlenosti od 69% zaposlenih u dobi između 20-64. godine u EU je niža u odnosu na razvijene zemlje svijeta a problem ubrzanog starenja stanovništva dodatno će opteretiti sustav socijalne skrbi. Uz to, opterećenost prirodnih resursa i okoliša ukazuju na ekološke izazove u svrhu čijeg rješavanja su potrebne drastične akcije ne samo na europskoj nego i na globalnoj razini. Kako bi izbjegla zaostajanje, povratila konkurentnost i potakla produktivnost te svoj pravac usmjerila prema vodećim svjetskim ekonomijama **EU mora ujedinjeno usmjeriti sva raspoloživa sredstva i instrumente** i suočiti se sa svim slabostima, preprekama i novim izazovima. (European Commission, 2010).

Predsjednik europske komisije Manuel Barroso za Panorama Info regio (2014) izvještava „Financijska i gospodarska kriza koja je pogodila globalno gospodarstvo u ljeto 2007. bez presedana je u europskoj poslijeratnoj gospodarskoj povijesti. Ipak, vjerujem da je najgori dio iza nas“. Smatra se da se kriza u većem dijelu europske uspela prebroditi, barem u pogledu egzistencije, a i situacije na financijskom tržištu što potvrđuju i najnovije brojke BDP – a. Napredak je ostvaren i u pogledu gospodarskog upravljanja EU a i povjerenje u europsko gospodarstvo se postupno vraća. Međutim iako se europa vraća na pravi put i izlazi iz gospodarske krize potrebno je nastaviti napore u borbi sa izazovima s kojima se suočavala i prije krize, koji su u strukturi dublje ukorijenjeni te koji su utjecaj krize samo još prdubili. Državama članicama se i dalje savjetuje da nastave da strukturnim reformama zadanih u konkretnim preporukama za države i ostvaruju daljnji napredak u onim područjima politika koja zahtijevaju koordinaciju.

U svrhu rješavanja navedenih problema EU i zemlje članice su u 2010. godini donijele novu strategiju za održiv rast, strategiju Europa 2020. Strategijom se utvrđuju svi temeljni akteri prosperiteta i produktivnost u budućnosti, bilo na području obrazovanja i osposobljavanja, klimatskih promjena, istraživanja i inovacije ili borbe protiv siromaštva. Nova strategija usmjerena je na rješavanje problema proizašlih iz globalne financijske krize i strukturnih reformi koje bi mjerama za povećanje rasta trebale vratiti konkurentnost europskog gospodarstva. U idućem

prikazani su temeljni prioriteti strategije, osnovni ciljevi, mjere za ostvarenje ciljeva te važnost politika i strukturnih fondova.

2.2. Strategija “Europa 2020”

Strategija “Europa 2020” donesena je 2010. godine s ciljem izlaska iz krize i pretvaranja EU u pametnu, održivu i uključivu ekonomiju kako bi se ostvarile visoke stope zaposlenosti, produktivnosti i društvene povezanosti. S tim u vezi temeljni prioriteti su (European Commission, 2010b):

1. ***pametan rast*** – razvoj gospodarstva utemeljenog na znanju i inovacijama,
2. ***održiv rast*** – promicanje zelenijeg, konkurentnijeg gospodarstva temeljenog na učinkovitom korištenju resursa,
3. ***uključiv rast*** – poticanje ekonomije visoke stope zaposlenosti uz rezultat ekonomske, socijalne i teritorijalne kohezije.

Strategijom su definirani slijedeći ciljevi koji bi se trebali ostvariti do 2020. godine:

- Podići stopu zaposlenosti osoba u dobi između 20-65 godina sa sadašnjih 69% na najmanje 75%, s većim uključivanjem žena, starijih te migranata u radno aktivno stanovništvo.
- 3% BDP-a EU-a treba investirati u ustraživanje i razvoj od strane privatnog i javnog sektora.
- Ispunjenje klimatsko - energetske ciljeve "20/20/20": smanjenje emisije stakleničkih plinova za 20%, ili 30% ako to dozvoljavaju uvjeti, u odnosu na 1990. godinu¹, povećati udio obnovljivih izvora energije na 20% u ukupnoj potrošnji energije te povećati energetske učinkovitost za 20%.
- Smanjenje postotka osoba koje rano napuštaju školovanje s trenutnih 15% na ispod 10%, istodobno povećavajući udio stanovništva u dobi između 31-34 godine koji završavaju tercijarno obrazovanje s trenutnih 31% na najmanje 40%.

¹ EU se zalaže za donošenje odluke za smanjenje emisija za 30% do 2020. u odnosu na razinu iz 1990. godine za period nakon 2012., pod uvjetom da se razvijene zemlje obvežu na usporedivo smanjenje emisija a da zemlje u razvoju doprinose adekvatno prema njihovim sposobnostima.

- Smanjiti broj stanovnika EU koji žive ispod nacionalne granice siromaštva za 25% čime bi 20 milijuna ljudi manje trebalo biti u opasnosti od siromaštva².

Navedeni ciljevi međusobno su povezani te nisu međusobno isključivi. Smatra se da su svi ciljevi jednako važni za sve zemlje članice, bez obzira na stupanj razvijenosti. Ciljevi ne predstavljaju te ih je s obzirom na specifičnosti zemalja članica potrebno prilagoditi na nacionalne ciljeve u navedenim područjima držeći se strateških i programskih smjernica Europske komisije. Osim toga određena su i najvažnija područja za djelovanje za koje se vjeruje da su novi pokretači za rast i zaposlenost. Ta područja identificirana su u okviru svake prioritetne teme kroz sedam glavnih inicijativa (European Commission, 2010 b):

i. Pametan rast

- **"Unija inovacija"** s ciljem poboljšanja uvjeta i dostupnosti financiranja za istraživanje i inovacije kako bi se inovativne ideje pretvorile u proizvode i usluge koje donose rast i radna mjesta.
- **"Mladi u pokretu"** s ciljem povećanja efikasnosti obrazovnog sustava i olakšanim ulaskom mladih na tržište rada.

ii. Održiv rast

- **"Digitalni program za Europu"** s ciljem širenja brzog interneta i korištenjem jedinstvenog digitalnog tržišta za kućanstva i tvrtke.
- **"Učinkovita Europa"** s ciljem održivog ekonomskog rasta, prijelaz na ekonomiju koja koristi male razine ugljena, povećanje korištenja obnovljivih izvora, modernizacija sektora transporta i promicanje energetske učinkovitosti.
- **"Industrijska politika za globalizacijsko doba"** s ciljem unapređenja poslovnog okruženja, posebno za male i srednje poduzetnike, te razvoj snažne i održive globalno konkurentne industrijske osnove.

² Nacionalne granica siromaštva definira se kao 60% nacionalnog medijana raspoloživog ekvivalentnog dohotka nakon socijalnih transfera.

iii. Uključiv rast

- **"Program za nove vještine i radna mjesta"** s ciljem modernizacije tržišta rada, jačanje cjeloživotnog obrazovanja i mobilnost radne snage kako bi se uskladila ponuda i potražnja na tržištu te povećao ukupan broj radno aktivnih.
- **"Europska platforma protiv siromaštva"** s ciljem jamčenja društvene i teritorijalne povezanosti na način da svi imaju koristi od prednosti rasta i radnih mjesta te da se ljudima koji pate od siromaštva i socijalne isključenosti pruži dostojanstven život i aktivno sudjelovanje u društvu.

Uz navedene prioritete i ciljeve, koji predstavljaju tematski pristup u ostvarenju rezultata strategije, nužna je i **evaluacija provođenja strategije** koja započinje svake godine s Europskim semestrom, kada države članice koordiniraju svoje ekonomske politike i aktivnosti u implementaciji strategije Europa 2020. Europski semestar osigurava da članice EU javno obaviještavaju o svojim makroekonomskim i strukturnim politikama te politikama zapošljavanja kako bi se pojačala koordinacija ekonomskih politika među zemljama članicama dok su one još u pripremi i na taj način otkrile nedosljednosti i neravnoteža. Komisija započinje Europski semestar svake godine kada predstavlja Europskom Parlamentu i Vijeću izvještaj pod nazivom "Godišnji pregled rasta". Na temelju tog dokumenta svaka država članica u suradnji sa nacionalnim stakeholderima donosi dva programa: "Nacionalni program reformi" i "Program stabilnosti i konvergencije". Prvi program se bavi pitanjem koliki pomak se je ostvario prema ciljevima strategije i koji koraci će se napraviti u nadolazećem razdoblju kako bi se ispravile ostale slabosti. Program stabilnosti i konvergencije bavi se sa višegodišnjim proračunskim planovima. Na temelju ova dva dokumenta stručnjaci Europske Komisije u suradnji sa državama članicama sastavljaju **specifične preporuke** za svaku zemlju zasebno, koje moraju biti potvrđene od strane Europskog Vijeća. Preporuke pokrivaju širok spektar tema koje odražavaju prioritete postavljene u "Godišnjem pregledu rasta" koje bi im trebalo pomoći da odrede i provedu svoje izlazne strategije, uspostve makroekonomsku stabilnost, utvrde nacionalna uska grla te vrate svoja gospodarstva na održiv rast i javne financije. Postavljeno razdoblje u kojem bi se konkretne i ciljane mjere trebale ostvariti iznose od 12 do 18 mjeseci. Zemlje članice Euro zone moraju Komisiji poslati skicu budžetskog plana kako bi Komisija procijenila je li koherentan sa nacionalnim programom reformi, programom o stabilnosti i konvergenciji te sa preporukama koje su poslane zemljama članicama (Europska komisija, 2012b).

2.3.Mjere za ostvarenje ciljeva strategije

Za ostvarenje ciljeva potreban je čitav niz aktivnosti na nacionalnoj i europskoj razini koji bi trebali biti međusobno povezani. Potrebno je ojačati **ključne politike, pravne akte i financijske instrumente** Europske unije kojima će se financirati realnu ekonomiju. Kriza je rezultirala sumnjom i razočarenjem jedinstvenim tržištem te je stoga potreban pravi politički angažman u otklanjanju ograničenja u prekograničnim aktivnostima. Tržište EU još uvijek nije u potpunosti ravnomjerno i tehnološki opremljeno u odnosu na konkurentnija tržišta Kine, SAD-a i Japana. Jače, prošireno i dublje jedinstveno tržište ključno je kako bi se olakšao pristup malim i srednjim poduzetnicima te krajnjim potrošačima iz svih zemalja članica čime bi se stimuliralo konkurentnost, stvorilo povoljno okruženje za inovacije što je u konačnici ključno za rast i nova radna mjesta. Omogućavanjem tržišnog natjecanja, otklanjanje protekcionizma, pružajući jednake mogućnosti za sve stvara se povoljno okruženje za inovacije (European Commission, 2010). U nastavku su opisane jedne od glavnih mjera za ostvarenje ciljeva strategije.

2.3.1.Kohezijska politika 2014. - 2020.

Manuel Barroso za Panorama Info regio (2014) ističe da je kohezijska politika jedan je od ključnih instrumenata za realiziranje ciljeva strategije Europa 2020. te ujedno i najveće ulaganje Europske unije u realno gospodarstvo. Kohezijska politika putem Europskog fonda za regionalni razvoj (ERDF), Europskog socijalnog fonda (ESF) i Kohezijskog fonda ostvaruje ciljeve strategije podupiranjem širokopojasnog pristupa, malih i srednjih poduzeća, socijalne uključenosti, obrazovanja, energetske učinkovitosti i otvaranja radnih mjesta. Iako ulaganja kohezijske politike od 2007. do 2013. bilježe mnogobrojna pozitivna iskustva, otvaranjem malih i srednjih poduzeća a time i novih radnih mjesta, rješavanje hitnih socijalnih i gospodarskih potreba proizašlih iz razdoblja krize, potreba za reformom u novom programskom razdoblju je bila neminovna. Reformirana kohezijska politika korištenjem fondova nastavlja sudjelovati u socijalnim i gospodarskim aktivnostima članica ali uz veliki naglasak na iskorištavanje sredstava u punom kapacitetu, njihov nadzor i izvještavanje te ispunjavanje određenih preduvjeta za korištenje sredstava iz strukturnih fondova. Osim toga Kohezijska politika također će biti usmjerena na jačanje gospodarske, socijalne i teritorijalne kohezije u Europskoj uniji ispravljanjem neravnoteže između regija.

Za postizanje ciljeva, tri fonda kohezijske politike (ERDF, ESF i Kohezijski fond) će podržati realizaciju 11 tematskih prioriteta. Za razliku na prijašnje razdoblje kada se kohezijska politika s ciljem konvergencije usmjerila isključivo na manje razvijene regije, reformiranom kohezijskom politikom **ulaganja** u regije i visina doprinosa regija EU-a, biti će prilagođena njihovoj razini razvijenosti i time ih svrstat u tri slijedeće kategorije: manje razvijene regije (BDP < 75 % od prosjeka EU-27); tranzicijske regije (BDP 75 % do 90 % od prosjeka EU-27); razvijenije regije (BDP > 90 % od prosjeka EU-27). Približno 100 milijardi eura Europskog fonda za regionalni razvoj (ERDF) usmjereno je na ključne sektore rasta te će se koncentrirat na prva četiri tematska prioriteta. Tako će se 50% sredstva izdvojiti na manje razvijene regije, 60 % na tranzicijske i 80% na razvijenije. Najmanje 23 milijarde eura iz ovih fondova podupirat će gospodarstvo s niskim emisijama ugljika (v. i vi. prioritet) i to 12% na manje razvijene regije, 15 % na tranzicijske regije i 20 % na razvijenije regije. Približno 66 milijardi eura ERDF-a bit će usmjereno na sedmu prioritetnu temu. Putem Europskog socijalnog fonda (ESF) kohezijska politika omogućit će znatan doprinos prioritetima pod brojem viii., ix. i x. putem obuke i doživotnog učenja, obrazovanja i socijalne uključenosti. Najmanje 20 % ukupnih sredstava ESF-a mora se dodijeliti promicanju socijalne uključenosti i borbi protiv siromaštva, s posebnim fokusom na mlade ljude (Panorama info regio, 2014).

Tematski prioriteti:

- i. Jačanje istraživanja, tehnološkog razvoja i inovacija
- ii. Poboljšanje pristupa informacijskoj i komunikacijskoj tehnologiji te njezine uporabe i kvalitete
- iii. Jačanje konkurentnosti MSP-ova, poljoprivrednog sektora (u sklopu EPFRR-a) te sektora ribarstva te akvakulture (u sklopu EFPR-a).
- iv. Podrška prelasku na ekonomiju s niskom razinom emisije CO₂ u svim sektorima,
- v. Promicanje prilagodbe na klimatske promjene, sprečavanje rizika i upravljanje njima,
- vi. Očuvanje i zaštita okoliša te promicanje učinkovitosti resursa,
- vii. Promicanje održivog prometa i uklanjanje uskih grla u infrastrukturi ključnih mreža.
- viii. Promicanje održivog i kvalitetnog zapošljavanja i podrška mobilnosti radne snage,

- ix. Promicanje socijalne uključenosti, borba protiv siromaštva i svake diskriminacije,
- x. Ulaganje u obrazovanje, osposobljavanje i stručno osposobljavanje za vještine i cjeloživotno učenje
- xi. Jačanje institucionalnog kapaciteta javnih tijela i zainteresiranih strana te učinkovite javne uprave.

Kao što je već spomenuto za postizanje što veće kontrole izdatih financijskih sredstava iz fondova poduprijetih kohezijskom politikom novog programskog razdoblja države članice moraju godišnje podnositi izvješća "Nacionalni program reformi" i "Program stabilnosti i konvergencije". Osim toga reformiranom kohezijskom politikom utvrđeni su i Preduvjeti za financiranje. Primjeri preduvjeta su strategije „pametne specijalizacije“, reforme koje potiču poslovanje, strategije prijevoza, mjere za poboljšanje sustava javne nabave ili zadovoljavanje ekoloških zakona koje je potrebno ispuniti prije nego se sredstva odobre kako bi se osiguralo učinkovito ulaganje. Reformiranom kohezijskom politikom se također mora utvrditi zajednička strategija kojom se postiže bolja koordinacija Europskih strukturnih i investicijskih fondova ESI fondovi (koji uključuju: ERDF, Kohezijski fond i ESF, temeljena na kohezijskoj politici, a također i fondovi za ruralni razvoj i ribarski fond, sa drugim instrumentima kao što su Obzor2020 i sl. Postavljanjem zajedničkih pravila za sve ESI fondove smanjuje se birokracija i pojednostavljuje procedura ulaganja. Naglasak je na povećanoj podršci financijskih instrumenata kao što su zajmovi, jamstva i dionički/poduzetnički kapital da bi se malim i srednjim poduzećima omogućila veća podrška i pristup kreditima (Panorama Info regio, 2014).

Hrvatskoj u sklopu „Operativnog programa konkurentnost i kohezija“ i prioritetne OSI 1 „Jačanje gospodarstva primjenom istraživanja i inovacija“ stoji na raspolaganju 334.321 mil € te prioritetne OSI 2 „Upotreba informacijskih i komunikacijskih tehnologija“ 209.370 mil € iz Europskog fonda za regionalni razvoj ali pod uvjetom donošenja strategije Pametne specijalizacije (MINGO, 2014). Na taj se način unaprijed definirana načinom potrošnje u ključna područja kojima se ostvaruje ulaganje u I&R te ICT koji su navedeni kao glavni pokretači rasta. U nastavku su prikazane neke od osnovnih značajki strategije i odabrana prioritetna područja za hrvatsku.

3. STRATEGIJA PAMETNE SPECIJALIZACIJE

3.1. Opće značajke strategije

Koncept strategije pametne specijalizacije (RIS3)³ je ustanovljen od grupe inovativnih znanstvenika 2009. godine pod vodstvom Dominika Foray-a te je u veoma kratkom vremenu ostvarila značajan politički utjecaj, a pogotovo u europski. Danas je strategija ključan element europskog inovacijskog plana za 2020. godinu. Važnost strategija pogotovo ukazuje činjenica da je od programskog razdoblja 2014. – 2020., postavljena kao ex ante uvjet za povlačenje sredstava iz Europskog fonda za regionalni razvoj za dva od jedanaest tematskih ciljeva: „Jačanje istraživanja, tehnološkog razvoja i inovacija“ te „Poljšanje pristupa informacijskoj i komunikacijskoj tehnologiji te njezine upotrebe i kvalitete“. Na temelju toga je Europska komisija odlučila izgraditi uslužnu platformu (S3) kako bi dali podršku regijama u njihovim naporima za osmišljavanje i provedbu strategije pametne specijalizacije, a OECD i Svjetska banka pokreću aktivnosti za promicanje i mjerenje pametne specijalizacije (Forray D, Policy Brief No.8). Ovakav veliku popularnost strategija stječe upravo u srži velikih svjetskih ekonomskih, gospodarskih i socijalnih događanja. Novom europskom strategijom kroz pametan, održiv i uključiv rast cilj je suprotstavljanje strukturnim slabostima koji su se već duboko ukorijenili na europski teritorij. Investiranje u istraživanje, inovacije i razvoj u srži je Europe 2020 i ključan odgovor europske na ekonomsku krizu stoga je potrebna strategija integriranog pristupa inovacijama koja će maksimizirati, Europski, nacionalni i regionalni istraživačko inovacijski potencijal (Foray, D. i dr. 2012).

Nacionalna/regionalna istraživačko inovacijska strategija za pametnu specijalizaciju (RIS3) je integrirana, agenda za ekonomsku transformaciju (Foray, D. i dr. 2012):

- i. Kojoj je glavni fokus usmjernost politika i investicija na ključne nacionalne/regionalne prioritete, izazove i potrebe za razvoj temeljen na znanju uključujući mjere za razvoj ICT – a.
- ii. Temelje se na snagama zemalja/regija, njihovim komparativnim prednostima i potencijalu za izvrsnost.

³ Research and Innovation Strategies for Smart Specialisation

- iii. Podržavaju tehnološke inovacije kao i inovacije bazirane na praksi sa ciljem stimulacije investicije privatnog sektora
- iv. Cilj je uključivanje stakeholdera i poticanje inovacija i experimentiranja.
- v. Bazirana na dokazima te uključuje sisteme praćenja i evaluacije.

Dosadašnje regionalne inovacijske strategije su imale nedostatke:

- i. Međunarodne i međuregionalne perspektiva, tako da su regionalni inovacijski i ekonomski sistemi često bili izolirani
- ii. Neusklađenost sa industrijskom i ekonomskom strujom regije, previše javnosti umiješano u istraživanje i razvoj
- iii. Nedostajala je analiza ukupnih regionalnih sredstava
- iv. Sindrom „ubiranja pobjednika“
- v. Regije najboljih performansi su se kopirale bez analize lokalnog konteksta

Stoga je temeljna odrednica koncepta pametne specijalizacije efektivna, efikasna i sinergijska upotreba javnih investicija i potpore u jačanju inovacijskih kapaciteta regija na način da se oskudne resurse fokusira na nekoliko globalnih konkurentskih područja kako bi ojačali ekonomski rast i prosperitet (Foray, D. i dr. 2012). Osnovna karakteristika strategije je da ne uključuje horizontalne mjere i neutralne politike kako bi se poboljšali opći uvjeti ljudskog kapitala, obrazovanja, intelektualnog vlasništva, infrastrukturu I&R i ICT-a, konkurentnost, otvorenost itd. Radije, pametna specijalizacija je više vertikalna i ne – neutralna logika intervencije, koja se bazira na identifikaciji i odabiru željenih područja intervencije u nekim tehnologijama, područjima, pod – sistemima koja bi mogla biti favorizirana (Forray, D., Policy Brief No.8). Vertikalni pristup podrazumijeva provođenje opsežnog postupka observacije i evaluacije područja i njezinog ekonomsko – socijalno – gospodarskih obilježja kako bi se na „pametno“ način otkrile domene tehnologije u kojima treba investirati, u kojim točno područjima, kojim grupama firmi. Stoga je pametna specijalizacija „pametna“ upravo zbog toga što povezuje inovacije i ekonomski razvoj na novi način, kao što su poduzetnički proces otkrivanja i postavljanja prioriteta od strane

donositelja politke u uskoj suradnji sa lokalnim akterima. Isto tako procesa se provodi sa uvidom u vanjski svijet, forsirajući regije da budu ambiciozne o tome što se može postići povezivanjem lokalnih resursa i pristupu vanjskim izvorima znanja i lancu vrijednosti (Foray, D. i dr. 2012). Strategija bi se trebala temeljiti na dostupnim resursima i potencijalu njihove iskoristivosti, identifikaciji konkurentskih prednosti te tehnološkoj specijalizaciji. Kod izrade strategije nastoji se utvrditi vlastite snage i prednosti te se pristupa principom „Odozdo prema gore“ kroz suradnju javnog, znanstveno istraživačkog i poslovnog sektora (Narodne novine, 2016).

3.2.Strategija Pametne Specijalizacije Hrvatske

Strategija pametne specijalizacije (S3) za Republiku Hrvatsku donešena je u Ožujku 2016. godine a sami proces izradi bio je jako zahtjevan i uključuje mnogo aktera na lokalnoj, regionalnoj i nacionalnoj razini. Strategijom se provodi sveukupna evaluacija upravljačkog kapaciteta javnog sektora, instrumenata za poticanje inovacija te ključnih osnova za inovacije. Potiče praćenje i vrednovanje te sektorsku analizu pet prioriteta područja gospodarstva. Glavni cilj strategije je povećanje konkurentnosti i transformacija hrvatskog gospodarstva, koncentrirajući resurse znanja te ih povezujući s ograničenim brojem prioriteta (NN, 2016).

S obzirom na veličinu hrvatske, koja se može usporediti sa veličinom regija u velikim zemljama članicama razlog je primjene koncepta pametne specijalizacije na nacionalnoj razini. U fazi pripreme, strategija je zahtijevala integrirani i teritorijalno temeljen pristup programiranju kako bi se stvorili uvjeti za razvoj RH u cjelini, time izbjegavajući mogućnost nejednakog razvoja regija i poštivanje regionalne različitosti. Kako bi se potakle strukturne promjene u hrvatskom gospodarstvu usmjeravajući njegov rast povećanjem istraživanja i inovacija na ujednačeni način strategijom će se potaknuti sinergijsko korištenje javnih sredstava za istraživanje, tehnološki razvoj i inovacije u cilju diversifikacije i modernizacije postojeće industrije (NN, 2016).

Vizija i glavni strateški ciljevi strategije za pametan uključiv i održiv rast Republike Hrvatske:

- i. Povećanje kapaciteta znanstveno-istraživačkog sektora za provedbu vrhunskih istraživanja u skladu s potrebama gospodarstva
- ii. Prevladavanje rascjepkanosti inovacijskog lanca vrijednosti i jaza između znanstveno istraživačkog i poslovnog sektora

- iii. Modernizacija i diverzifikacija hrvatskog gospodarstva kroz ulaganja poslovnog sektora u istraživanje, razvoj i inovacije
- iv. Nadogradnja u globalnom lancu vrijednosti i poticanje internacionalizacije hrvatskog gospodarstva
- v. Partnerski rad na rješavanju društvenih izazova
- vi. Razvoj pametnih vještina – unaprjeđenje kvalifikacija postojeće i nove radne snage za pametnu specijalizaciju

Konačna prioritetna tematska područja određena su sinergijom prioriteta sektorskih strategija (strategija znanosti, obrazovanja i tehnologije, industrijske strategije, inovacijske strategije, strategije turizma) i prioriteta utvrđenih procesom otkrivanja poduzetnika – uspostavom klastera konkurentnosti i analizom znanstveno-istraživačkog sektora. To su: zdravlje, održivi okoliš i energija, inženjerstvo, biotehnologija i bio ekonomija. Prepoznati su horizontalni preklapajući sektori: KET i ICT, turizam, kreativne i kulturne industrije, zeleni rast i društveni izazovi (NN, 2016).

Strategija pametne specijalizacije zajedno sa energetsom strategijom, strategijom gospodarenja mineralnim sirovinama RH, strategijom poticanja investicija, strategijom razvoja poduzetništva i politikom razvoja ljudskih potencijala čine temelj za kreiranje gospodarske razvojne strategije RH.

i. Inovacijska strategija

Strategijom poticanja inovacija Republike Hrvatske nastoji se osigurati koordiniran pristup održivom društveno-gospodarskom razvoju kroz uspostavu učinkovitog inovacijskog sustava koji će povezivati upravljanje inovacijskom politikom odozgo i odozdo. Uspješnost strategije ovisi o ostvarenom rezultatu svakog zacrtanog cilja. Rezultati strategije očituju se kroz odabrane statističke pokazatelje: udio bruto domaćih izdataka za istraživanje i razvoj u BDP-u, udio ulaganja poslovnog sektora u ukupnim ulaganjima za R&D, udio istraživanja sa inovacijskim potencijalom u ukupnim istraživanjima, broj registriranih patenta na milijun stanovnika, udio stranih investicija u R&D, broj istraživača u ukupnom broju zaposlenih (MINGO, 2014b).

Slika 1: Strategija pametne specijalizacije kao dio gospodarske strategije



Izvor: MINGO, http://www.regionalna-konkurentnost.hr/userdocsimages/Pametna_specijalizacija_i_%20rast_u_%20Republici_%20Hrvatskoj.pdf

Hrvatska ima razmjerno niska ulaganja u R&D u usporedbi sa ostalim europskim zemljama, tek 0,81% BDP-a, sa niskim udjelom poslovnih ulaganja od 43%. To je daleko ispod prosjeka EU koji je u 2013. iznosio 2% BDP-a i 55% BERD-a. Prema inovativnosti i uzetim pokazateljima Hrvatska se nalazi u skupini slabije razvijenih europskih zemalja kao što su Bugarska, Poljska i Latvija. Broj registriranih patenata na milijun stanovnika iznosi 6,6 dok je prosjek EU 108 patenata. Također Luksemburg i Skandinavske zemlje broje više od 10 istraživača na 1000 zaposlenih dok Hrvatska ako bi ostvarila zacrtani cilj, odnosno povećanje broja istraživača za 30% do 2020., ne bi ušla u europski prosjek iz 2013.5 (MINGO, 2014b)

ii. Industrijska strategija

Industrijska strategija donesena je za šestogodišnje razdoblje 2014.-2020. i obuhvaća prerađivačku industriju, građevinarstvo, informacije i komunikacije. Glavni cilj industrijske strategije je repozicioniranje identificiranih strateških djelatnosti na globalnom lancu vrijednosti prema razvoju aktivnosti koje stvaraju dodanu vrijednost (MINGO, 2014a).

Strategijom su identificirane dvije visoko-tehnološke djelatnosti u Hrvatskoj: proizvodnja osnovnih farmaceutskih proizvoda i farmaceutskih pripravaka, proizvodnja računala te

elektroničkih i optičkih proizvoda. Od djelatnosti sa srednje visokom tehnološkom intenzivnosti istaknuta je proizvodnja ostalih prijevoznih sredstva (željezničke lokomotive i tračna vozila, vojna borbeno vozila) sa 12,3 % udjela u BDV-u prerađivačke industrije (MINGO, 2014a).

Kao strateške djelatnosti određene su one aktivnosti koje zahtijevaju visoki-tehnološki intenzitet. Farmaceutska industrija koja je u 2012. godini ostvarila 4.64% BDV-a prerađivačke industrije, zapošljavala 41.595 odnosno 1.84% od ukupno zaposlenih u prerađivačkoj industriji. Zatim proizvodnja računala te elektroničkih i optičkih proizvoda ostvaruje tek 3.19% i zapošljava 2,65% zaposlenih u prerađivačkoj industriji (MINGO, 2014a).

iii. Strategija razvoja turizma

Strategija razvoja turizma ima za cilj postizanje prepoznatljivosti hrvatskog turizma, očuvanje održivosti i povećanje atraktivnosti investicijskog okružja.. Stoga su postavljeni strateški ciljevi do 2020. godine (Ministarstvo turizma, 2014):

- poboljšanje strukture i kvalitete smještaja,
- povećanje utjecaja turizma na zapošljavanje,
- privlačenje novih investicija,
- povećanje turističke potrošnje i plasman domaćih proizvoda i usluga kroz turizam.

Raspoloživi smještajni kapaciteti u hrvatskom turizmu ostvaruju uzastopni rast. U odnosu na prošlo desetljeće najveći rast bilježi privatni smještaj sa 47%, potom hoteli sa 19% i kampovi 12% (Vlada RH, 2014).

Najveći adut hrvatskog turizma i njegov proizvod oduvijek je sunce i more sa fizičkim obujmom od 85%. Dijelom je tako i zbog nerazvijenosti ostale ponude. Također, sunce i more čine Hrvatsku prirodno privlačnu nautičarima. Ipak nautički turisti nisu dovoljno zastupljeni u ukupnom broju turista zbog nedovoljne ponude vezova i nepovoljne investicijske klime. Slično se događa i sa poslovnim turizmom. Iako ne dovoljno poznato, čak 10% - 15% hotelskih gostiju čine poslovni gosti. Taj postotak mogao bi se povećati ulaganjem u kongresnu infrastrukturu (Vlada RH, 2014).

Kako je strategija donešena na nacionalnoj razini zbog svoje veličine, postoji opasnost nejednakog razvoja hrvatske a pogotovo od pripajanja panonske i kontinentalne hrvatske u jednu regiju od trenutka ulaska u europsku uniju. Iako se ističe da je omogućen jednaki razvoj regija neki autori ističu regije kao važan izvor ekonomskog razvoja i organizacije u globaliziranoj ekonomiji (Amin, 1999; Cooke, 1997; Malecki, 2007; Scott, 1995; Werker & Athreye, 2004 navedeno u Huggins, R. i dr., 2013). fokus na regije reflektira rastućim konsenzusom da su upravo one primarne prostorne jedinice koje se natječu u privlačenju investicija i na regionalnoj razini znanje cirkulira i prenosi se rezultirajući u aglomeracijama, klasterima u industrijskim i/ili uslužnim djelatnostima. Generalno regije se smatraju važnim izvorom ekonomskog razvoja i organizacije u globaliziranom svijetu (Malecki, 2007 navedeno u Huggins, R. i dr., 2013). Preporuka OECD – a (2013) je također da se strategija pametne specijalizacije provede na regionalnoj razini. U nastavku rada će se analizirati koliko su regije hrvatske slične da bi se provela jedna strategija na nacionalnoj razini a prije toga će se odrediti varijable prema kojima se dvije regije definiraju kao slične.

4. REGIONALNI BENCHMARKING U RIS3 PROCESU

Podrijetlo pojma benchmarkinga nije sasvim poznato, benchmark iz kojeg je nastao pojam benchmarkinga potječe iz građevinske terminologije, označavajući spravu za određivanje visina različitih točaka zemljine površine i poravnavanje pomoću vodoravnih pravaca (nivelir). Međutim njegovi oblici su vidljivi još u starom vijeku, kada se prilikom donošenja odluka uspoređivalo sa drugima kako bi se procijenile njihove snage i slabosti. Sa stajališta proizvođa benchmarking se upotrebljava od početka 20. stoljeća kako bi se shvatila konkurencija, njezin način rada i funkcioniranje konkurentskih proizvoda (Renko N. i dr., 1999). Dok je literatura iznjedrila mnogobrojne definicije banchmarkinga poduzeća, većina njih dijeli zajednički nazivnik: utvrđivanje vlastitog stanja organizacije i pozicije na tržištu, analiziranje performanse drugih poduzeća, definiranje područja i uzroke konkurentnosti, te primjena najbolje prakse kopirajući poduzeća s najboljim rezultatima.

4.1. Regionalni benchmarking i RIS3

Postoje mnoga područja primjene benchmarkinga unutar poduzeća: usporedbe proizvoda, troškova i financija, upravljanje i organizacija, istraživanje i razvoj i dr. (Renko N. i dr., 1999) a kao rezultat povećane regionalne i nacionalne konkurentnosti proizašle iz globalizacije, benchmarking se počeo primjenjivati i na teritorijalni kontekst, prvo na nacionalnu a onda i regionalnu razinu te u kontekstu politika europske unije (Koellreuter, 2002 navedeno u Navarro i dr., 2014). Preuzimanje koncepta koji je razvijen za promatranje poduzeća, manje organizacijske jedinice, i primjeniti ga na teritorij, veću i kompleksniju teritorijalnu jedinicu koja je u srži strukturirana na potpuno drugačiji način, izazovan je i rizičan potez. A osim toga postavlja se i pitanje koje dvije teritorijalne jedinice se mogu međusobno uspoređivati (Navarro M.i dr., 2014).

Uspoređivati se mogu susjedne regije, regije iste zemlje, regije koje žele kooperirati i učiti jedna od druge te regije koje se suočavaju s jednakim problemima i izazovima. A upravo se usporedba regija koje se suočavaju sa jednakim problemima i izazovima smatra najkorisnijom (Besant & Rush, 1998; Dunnewijk et al., 2008; Soete and Corpakis, 2003 navedeno u Navarro i dr., 2014). Papaioannou i dr. (2006) kako je navedeno u radu Navarra i dr. (2014) naglašava princip usporedbe temeljen na sličnosti entiteta koje se uspoređuju kao ključni uvjet koji mora biti ispunjen. Međutim, Archibugui and Coco, 2004; Archibugi et al., 2009 prema Navarro i dr. (2014) ističu da regije iako različite mogu također učiti jedna od druge ali pod pretpostavkom da je kontekst uzet u obzir,

odnosno da regije suštinski slične jedna drugoj. „U suprotnosti sa naivnim i jednostavnim benchmarkingom, inteligentan ili sistemski tip benchmarkinga bi se trebao konstruirati i implementirati“ (Lundvall i Tomlinson, 2001 navedeno u Navarro M. i dr., 2014). Prema Nauwealaers i dr. (2003) kako je navedeno u radu Navarro i dr. (2014) takav tip benchmarkinga bi trebao uzet u obzir kontekst u kojem su se prakse i politike razvile.

Benchmarking metodologija za dizajn i implementaciju regionalnog RIS3 prema Goenendijk, 2010; Iurkovich i dr., 2006 navedeno u Navarro M. i dr. (2014) podrazumijeva **benchmarking politike i inovacijskog sistema** koji bi trebao slijediti nekoliko koraka. Prvi korak je identifikacija regija za usporedbu, te analizirati one sa boljim performansama (Lall, 2001; Balzat, 2006; Edquist, 2008 navedeno u Navarro M. i dr., 2014). U trećem koraku primjerenom lošijih performansi (Edquist, 2001 navedeno u Navarro i dr., 2014). A u zadnjem, ali ništa manje važnom koraku, potrebno je benchmarking analizu implementirati, uskladiti politke, kontrolu i reviziju u suprotnome je njezino provođenje bilo beskorisno (Balzat, 2006; Paasi, 2005; Polt, 2002 navedeno u Navarro M., 2014).

Benchmarking bi mogao doprinijeti u razvoju strategije pametne specijalizacije u svih šest koraka. U prvoj, *dijagnostičkoj fazi*, prema OECD (2005) navedeno u radu Navarra M. i dr. (2014) benchmarking analiza bi mogla pomoći u identifikaciji snaga i slabosti teritorija a analiza regionalnog konteksta i potencijala za inovaciju bi se trebao u velikoj mjeri bazirati na banchmarking analizi (Walendowski i Roman, 2012 navedeno u Navarro i dr., 2014). Kao što ističu Iurkovich i dr. (2006) navedeno u radu Navarra i dr. (2014), proces regionalnog benchmarkinga podiže svijest lokalnih stakeholdera o relativnoj poziciji regije, što bi moglo motivirati i obvezati regionalne donositelje odluka i time doprinijeti procesu *upravljanja* što predstavlja drugi i treći korak dizajn istraživačko, inovacijske strategije. *Postavljanje seta prioriteta* za razvoj jedinstvenih regionalnih vrijednosnih propozicija predstavlja četvrti korak u dizajniranju RIS3 stoga bi prema Niosi, 2002 navadeno u Navarro i dr. (2014) analiza slabosti i snaga trebala biti popraćena analizom zamišljenih prioriteta postavljenih od drugih regija. Kombinacija politika, putokaza i akcijskih planova primjenom benchmarkinga razvija se dublje *razumijevanje odrednica inovacija u konkurentnosti*, te pruža neprocijenjive informacije o sastavljanju prave strategije što čini peti korak RIS3 strategije. I konačno benchmarking omogućuje regijama da provjeravaju i prate ostvarivanje svojih ciljeva ili smanjivanje razlika između perfomansi u određenom području u

odnosu na najbolje plasirane konkurente (Niosi, 2002 navedeno u Navarro i dr., 2014) što predstavlja šesti korak strategije.

4. 2. Određivanje varijabli za identifikaciju strukturnih karakteristika

Biranje regija za usporedbu prvi je korak regionalnog benchmarkinga. Međutim prije nego što se odrede koje će se regije uspoređivati međusobno, postavlja se pitanje prema kojim kriterijima se neke regije definiraju kao slične. Do sada su već brojni autori analizirali karakteristike prema kojima se regije definiraju kao homogene a Navarro M. i dr. (2014) su proučavali faktore koje su oni koristili da bi regije svrstali u istu skupinu. Zaključeno je da su dimenzije koje oni koriste strukturne prirode, što znači da nemogu biti promijenjene u kratkom roku i utjecati na stupanj ili način na koji se inovacije odvijaju u regiji. Stoga oni čine fundamentalne uvjete koji bi se trebali uzeti u obzir kod dizajna regionalnog RIS3.

Međutim BDP per capita, spomenuta od većine autora nije strukturni ili temeljni uvjet. Lall (2001) kako je navedeno prema Navarro M. i dr. (2014) tvrdi da je razlog tome u dvostranoj uzročnoj vezi između BDP per capita i inovacija. BDP per capita je rezultat, radije nego početna točka procesa inovacija i konkurentnosti stoga nije prikladan za identifikaciju grupe regija koje se suočavaju sa sličnim izazovima proizašle iz njihovih sličnih strukturnih uvjeta (Niosi, 2002 navedeno u Navarro M. i dr., 2014). Također postojeća tipologija je do sada miješala varijable različite prirode, kombinirajući one strukturnih uvjeta, ponašanja i performansi. Razrađivanje regionalne tipologije je najbližiji način da se riješi ovo pitanje. Ali čak i kad se sačinjavala klaster analiza sa varijablama koje identificiraju regije jednakih strukturnih karakteristika, u rezultirajućoj grupi homogenih regija nedostaje mnogo važnih regija. Postoji potreba za novim pristupom za regionalni benchmarking, koji će biti objašnjen u idućem odjeljku. (Navarro i dr., 2014).

Stoga u svome radu na temelju prethodno primjenjivanih karakteristika za određivanje homogenosti regije Navarro M. i dr. (2014) vrše selekciju i odvajaju varijable koje po svojim obilježjima definiraju strukturni karakter regije. Definirali su sedam različitih dimenzija od kojih je svaka od dimenzija podijeljena na elemente koji su definirani kroz jednu ili više nadomjesnih, proxy, varijabli. Istraživanje je provedeno na razini NUTS II⁴ regija europske unije. Navedena

⁴ Osim regija zemalja Belgije, Njemačke i Velike Britanije u kojima se istraživanje provelo na razini NUTS I. Odluku o tome na kojoj regionalnoj razini provoditi istraživanje temelji se na tome gdje počivaju regionalne moći države.

podjela s detaljnim objašnjenjem svake varijable i korištenih jedinica mjere te izvori podataka nalaze se u *Tablici 1*. Izračunate vrijednosti varijabli za svih 205 regija su stavljene na raspolaganje te će biti korištene i za potrebe ovog istraživanja. Kako je hrvatska netom prije ušla u punopravno članstvo europske unije, nije bila obuhvaćena ovom analizom pa se njezine vrijednosti ne mogu naći u tablici sa ostalim regijama. Stoga je prvi zadatak prije utvrđivanja referentne regije određivanje vrijednosti jadranske i kontinentalne hrvatske za svaku pojedinu varijablu definiranu od strane Navarra i dr. (2014), te će biti obuhvaćeno ovim poglavljem.

4.2.1. Geo demografski indikatori

Unutar geo demografske dimenzije uključeno je pet elemenata. Naseljenost regije, se koristiti kao zamjenska varijabla za **veličinu regije**. Iako se veličina regije nemože u potpunosti prikazati kroz ukupnu populaciju, koristi se kao zamjenska varijabla za objašnjavanje veličin regije. Kontinentalna hrvatska po broju stanovnika spada u europski prosjek dok je jadranska hrvatska ispod prosjeka. Europska regija NUTS II razine koja broji najviše stanovnika je njemačka regija Nordrhein – Westfalen⁵ a najmanje broji talijanska regija Valle d'Aosta. Podatci su preuzeti sa EUROSTAT⁶ –a za 2011. godinu kao što je i u izvornom dokumentu Navarra et.al (2014).

Urbanizacija koja zamjenjuje tradicionalno korištenu "gustoću naseljenosti" se računa kao postotak populacije koja živi u gradovima ili tzv. zonama dnevne migracije „Commuting zone“⁷. Podatci za jadransku i kontinentalnu hrvatsku su prikupljeni u EUROSTAT⁸-u gdje se u sklopu broja stanovnika funkcionalnih urbanih sredina nalaze Grad Zagreb, Osijek, Slavonski Brod, koji spadaju pod kontinentalnu hrvatsku, a gradovi Split, Pula, Rijek, Zadar pod jadransku. Zbrajanjem broja stanovnika funkcionalnih urbanih sredina svake regije i dijeljenjem sa ukupnim brojem stanovnika svake regije dobiven je postotak stanovništva funkcionalne urbane sredine. Podatci za ostale regije izračunate od strane Navarra et.al (2014) su iz 2006.godine dok se za jadransku i kontinentalnu hrvatsku upotrebljavaju podatci iz 2016. Prethodno navedenim postupkom dobije se da 55,73% stanovništva jadranske regije dnevno putuje u grad u svrhu obavljanja posla, dok u kontinentalnoj hrvatskoj čak manje 53,79%. Najveći postotak na razini EU je 100% a odnosi se na

⁵ Međutim treba uzeti u obzir sa su u istraživanju njemačke regije NUTS I kategorije

⁶ http://appsso.eurostat.ec.europa.eu/nui/show.do?dataset=demo_r_d2jan&lang=en

⁷ Zona dnevne migracije „Commune zone“ uključuje šire geografsko područje od administrativnih podjela, u kojima više od 15% rezidenata na dnevnoj bazi putuje u grad u svrhu obavljanja rada (European Commission, 2012c)

⁸ http://appsso.eurostat.ec.europa.eu/nui/show.do?dataset=urb_lpop1&lang=en

sve europske metropole Bratislav Kraj, Comunidad de Madrid, Bremen, Hamburg, Berlin, Praha, Region de Bruxelles Capitale, Wien. S druge strane neke regije imaju 0% stanovnika koji putuju na dnevnoj bazi radi obavljanja posla, austrijska regija Vorarlberg, grčke regije Dytiki Makedonia, Ionia Nisi, Voreio Aigaio i Notio Aigaio, talijanska regija Valle d'Aosta, švedske regije Norra Mellansverige i Mellersta Norrland.

Starosna dob stanovništva regije računa se tako da se uzme u obzir postotak populacije starih 65 godina i više te postotak populacije mlađih od 15 godina. Podatci su dobiveni iz baze podataka EUROSTAT⁹ na temelju regija NUTS III kategorije, koji su se dalje zbrajali po županijama iz svake regije i podijelili sa ukupnim brojem stanovništva. I jadranska i kontinentalna hrvatska imaju veći postotak osoba starih i starijih od 65 godina od postotka populacije mlađih od 15 godina. Po postotku populacije starih i starijih od 65 jadranska hrvatska sa 18,32% i kontinentalna sa 17,44% spadaju u europski prosjek dok su kod postotka populacije mlađe od 15 godina malo ispod europskog prosjeka. Talijanska regija Liguria (26,85%) ima najveći broj populacije starije od 65 a sa 10,12% najmanji postotak populacije stare 65 i više godina broji nizozemska regija Flevoland. Irska regija Border, Midlands and Western sa 23,59% broji najveći postotak populacije mlađe od 15 godina a najmanji postotak ih ima u španjolskoj regiji Principado de Asturias (11,49%).

Posljednji geografski faktor, **indeks pristupačnosti** omogućuje da se simultano uzme u obzir lokalna infrastruktura i pristupačnost tržištu. Međutim s obzirom na njihovu složenost, ovi indeksi se ne obnavljaju tako često. Stoga su Navarro et.al (2014) ovdje koristili multimodalni indeks pristupačnosti koji je sastavljen od ESPON-a u 2006. godini kao mjera pristupačnosti. Međutim u dostupnom istraživanju iz 2006. godine, podataka za jadransku i kontinentalnu hrvatsku nema, a podatci kasnijih istraživanja još nisu otvoreni javnom korištenju te zbog složenosti samog indikatora teško je pronaći zamjensku varijablu. Stoga je ova varijabla otklonjena te neće biti uvrštena u daljnju analizu.

4.2.2. Razina obrazovanja ljudskog kapitala

Za procjenu **razine obrazovanja ljudskog resursa** ne procijenjuje se, kao što je uobičajeno, mlađa generacija školske i akademske dobi, jer bi to bio više input nego strukturna varijabla koja bi mogla biti pod utjecajem javnih politika kako bi se poboljšale performanse regija i njezin potencijal.

⁹ http://appsso.eurostat.ec.europa.eu/nui/show.do?dataset=demo_r_pjanaggr3&lang=en

Umjesto toga procjenjuje se postotak populacije u dobi od 25–64 koja je dosegla više srednje i tercijarno obrazovanje jer je to prikladniji način da se izmjere strukturne razlike. Kompletni podatci dobiveni su iz baze podataka EUROSTAT¹⁰ za godinu 2012. Prema rezultatima, jadranska hrvatska sa 85,2% u odnosu na 78,1% kontinentalne hrvatske ima veću razinu višeg srednjeg i tercijarnog obrazovanja populacije od 25 – 64 godina. Na europskoj razini najveći postotak ostvaruje češka regija „Praha“ sa 96,1 % a najmanji poljska regija Łodzkie sa 31,8%.

¹⁰ http://appsso.eurostat.ec.europa.eu/nui/show.do?dataset=edat_lfse_04&lang=en

Tablica 1: Varijable za određivanje regija jednakih strukturnih karakteristika

DIMENZIJA	ELEMENT	VARIJABLE	IZVOR I GODINA	DIMENZIJA	ELEMENT	VARIJABLE	IZVOR I GODINA
1. Geo - demografski	Regionalna veličina	Ukupna populacija	Eurostat; 2011	4. Sektorska struktura	Sektorska koncentracija	Top 5 podsektora (2jedinice) (% ukupne zaposlenosti)	Eurostat LFS
	Starost	Populacija >=65	Eurostat		Industrijska sektorska struktura	Rudarstvo i vađenje (05-09)	Eurostat LFS
		Populacija <15	Eurostat			Hrana, piće, duhan (10-12)	Eurostat LFS
	Urbanizacija	Populacija u urbanim i dnevnim migracijskim zonama	DG Regio			Tekstil, odjeća i koža (13-15)	Eurostat LFS
	Pristupačnost	Multimodalna pristupačnost	ESPON			Drvo, papir i tisak (16-18)	Eurostat LFS
2. Razina obrazovanja	Razina obrazovanja	Populacija sa višim srednjim i terciarnim obrazovanjem	Eurostat			Kemija, Farmacija, guma, plastika i rafinirana nafta (19-22)	Eurostat LFS
3. Tehnološka specijalizacija	Teh. distribucija (patenti)	Električni inženjering	OECD REGPAT			Ne metalni, mineralni proizvodi (23)	Eurostat LFS
		Instrumenti	OECD REGPAT			Osnovni metali i metalni proizvodi (24-25)	Eurostat LFS
		Kemija	OECD REGPAT			Električna, elektronska, kompjuterska i optička oprema (26-27)	Eurostat LFS
		Mehanički inženjering	OECD REGPAT			Mašinerija (28)	Eurostat LFS
		Ostala područja	OECD REGPAT			Transportna oprema (29-30)	Eurostat LFS
		Gini indeks od 35 podpodručja	OECD REGPAT			Ostala proizvodnja (31-33)	Eurostat LFS
	Teh. koncentracija						
4. Sektorska struktura	Ekonomska sektorska distribucija	Poljoprivreda, šumarstvo i ribolov (A)	Eurostat LFS	5. Veličina poduzeća	Veličina poduzeća	Prosječna veličina poduzeća	Eurostat SBS
		Industrija (osim građ.) (B-E)	Eurostat LFS	6. Otvorenost	Trgovinska otvorenost	Ukupan izvoz (%BDP-a)	Fraunhofer ISI & Orkestra
		Građevinarstvo (F)	Eurostat LFS	7. Institucije i vrijednosti	Višedimenzijska država	Decentralizacija	BAK Basel Econom.
		Trgovina na veliko i malo, transport i sl. (B-I)	Eurostat LFS		Socijalni i institucionalni kapital	Kvaliteta institucija	Charron i dr.
		Informacije i komunikacije (J)	Eurostat LFS			Osjećaj sigurnosti hodanja sam u lokalnom području po mraku	ESS
		Financijske i osiguravajuće aktivnosti (K)	Eurostat LFS			Većini ljudi se može vjerovati ili nikad ne može biti pre siguran	ESS
		Nekretnine (L)	Eurostat LFS				ESS
		Profesionalne, znanstvene i tehničke aktivnosti (M-N)	Eurostat LFS				
		Javna administracija (O-Q)	Eurostat LFS		Poduzetnički/inovativan stav	Važno je smišljati nove ideje i biti kreativan	
		Umjestnost, zabava i rekreacija (R-U)	Eurostat LFS			Važno je probati nove i drugačije stvari u životu	

Izvor: Navarro, M. i dr., 2014

4.2.3. Tehnološka specijalizacija

Tehnološka područja specijalizacije u regiji su definirana obzirom na dvije podkategorije: tehnološka distribucija i tehnološka koncentracija. Za **tehnološku distribuciju** patenata se procijenjuje postotak distribucije patenata baziranom na temelju međunarodne prijave patenata (PCT)¹¹ među pet velikih tehnoloških područja¹², korištenjem WIPO's IPC tehnološkog registra¹³. Podatci su sastavljeni na temelju OECD baze podataka ali s obzirom na mali broj prijavljenih patenata godišnje u nekoliko regija, koristila se distribucija patenata prijavljenih u periodu od 2005 – 2010 godine. Za regije jadranske i kontinentalne hrvatske nije bilo dostupnih podataka na temelju prethodno opisane raspodjele stoga se je koristila podjela patenata dostupna u bazi OECD PATSTAT, patentu prema sektoru i TL3¹⁴, na temelju koje se je računala tehnološka distribucija patenata za jadransku i kontinentalnu hrvatsku i sve ostale regije EU. Tako se je umjesto broja prijavljenih patenata u područjima „Električni inženjering, Instrumenti, Kemija, Mehanički inženjering te Ostala područja“ koristila prijava broja patenata u sektorima „Biotehnologija, ICT, Nanotehnologija, Medicinska tehnologija i Farmacija“. Prvo se je zbrajao broj prijavljenih patenata sa TL3 na TL2 razinu za svaki pojedini sektor i ukupan broj patenata u vremenskom prirodu od 2009 – 2013¹⁵, zatim je zbroj patenata svakog pojedinog sektora podijeljen sa ukupnim brojem patenata u svih pet tehnoloških područja kao što je prikazano na slici ispod. Na isti način računala je se distribucija i ostalih regija.

Iz slike je vidljivo da je u periodu od 2009. – 2013. broj patenata prijavljen u kontinentalnoj hrvatskoj skoro za četiri puta veća nego u jadranskoj regiji. Isto tako sama struktura prijavljenih patenata u dvije regije se dosta razlikuje, patentu kontinentalne hrvatske se u većem broju

¹¹ Ugovor o suradnji na području patenata (Patent cooperation treaty), čiji je član i hrvatska omogućuje da se prijavom patenta u jednoj zemlji ili regiji patent automatski registrira na međunarodnoj razini (www.dziv.hr).

¹² (I) Električni inženjering, (II) Instrumenti, (III) Kemija, (IV) Mehanički inženjering i (V) ostala područja

¹³ „World intellectual property organization“ klasifikaciju patenata temelji na tehnologijama ili proizvodima koji koriste određene tehnologije.

¹⁴ Territory Level 3, jedna od dvije razine geografskih cjelina definiranih od strane OECD – a koja je jednaka administrativnoj podjeli na NUTS 3 razinu, odnosno TL2=NUTS2, od strane EUROSTAT-a.

¹⁵ U izvornom radu Navarra et.al (2014.) je korišten period od 2005. – 2010. ali zbog nedostupnih podataka za taj period koristila se distribucija prijavljenih patenata od 2009. – 2013.

prijavljaju u području ICT –a i Farmacije dok je to u jadranskoj regiji u području medicinske tehnologije.

Tablica 2: Distribucija patenata jadranske i kontinentalne hrvatske u periodu od 2009. - 2013.

<i>Distribucija patenata jadranske hrvatske u periodu od 2009. - 2013.</i>						
Godina	Ukupno patenata					Ukupan broj patenata u 5 tehnoloških područja
	Biotehnologija	ICT	Nanotehnologija	Medicinska tehnologija	Farmacija	
2009	0,00	0,50	0,00	1,00	0,75	2,25
2010	0,00	0,00	0,00	0,00	1,58	1,58
2011	2,00	1,00	0,00	2,00	1,00	6,00
2012	0,50	1,83	0,00	3,00	0,00	5,33
2013	1,50	1,50	0,00	1,00	1,50	5,50
Σ	4,00	4,83	0,00	7,00	4,83	20,67
%	19,35%	23,39%	0,00%	33,87%	23,39%	100%
<i>Distribucija patenata kontinentalne hrvatske u periodu od 2009. - 2013.</i>						
Godina	Ukupno patenata					Ukupan broj patenata u 5 tehnoloških područja
	Biotehnologija	ICT	Nanotehnologija	Medicinska tehnologija	Farmacija	
2009	1,50	3,50	0,00	0,14	7,63	12,77
2010	2,17	8,67	0,00	0,17	9,65	20,65
2011	2,00	7,75	0,00	0,00	5,64	15,39
2012	2,50	4,67	0,00	0,00	2,00	9,17
2013	1,50	8,77	0,00	1,00	5,06	16,33
Σ	9,67	33,36	0,00	1,31	29,98	74,31
%	13,01%	44,89%	0,00%	1,76%	40,34%	100,00%

Izvor: OECD: <https://stats.oecd.org/> , izračun autora

Iako je i na temelju *Tablice 2* vidljivo da je prijavljeni broj patenata kontinentalne hrvatske koncentriran na isključivo dva područja tehnologije, izračunat je i Gini koeficient¹⁶ distribucije patenata prijavljenih za period od 2009. – 2013 koji predstavlja mjeru **tehnološke koncentracije**. U *Tablici 3* prikazan je izračun Gini indeksa za jadransku i kontinentalnu hrvataku na kojoj je također vidljivo na temelju koeficienta, koji je bliži 0, da je jednakosti prijavljivanih patenata u

¹⁶ Gini koeficient je mjera koja se najčešće koristi za računanje dohodovne nejednakosti, ali može se koristiti za računanje bilo koje raspodjele. Što je vrijednost bliža 0 to je manja nejednakost odnosno veća jednakost.

jadranskoj hrvatskoj veća nego u kontinentalnoj. Na isti način izračunata je i tehnološka koncentracija ostalih regija EU.

Tablica 3: Gini index koncentracije patenata jadranske i kontinentalne regije

<i>Gini indeks koncentracije patenata kontinentalne regije</i>						
Tehnologije	%Tehnologije	% Patenata	Kum. % Patenata	Područje Ispod Lorenzove krivulje		
0	0%	0%	0%	0		A
1	20%	0,00%	0%	0		0,26
2	40%	1,76%	2%	0,00		
3	60%	13,01%	15%	0,02		Gini
4	80%	40,34%	55%	0,07		0,51
5	100%	44,89%	100%	0,16		
		100,00%		0,24		


<i>Gini indeks koncentracije patenata jadranske regije</i>						
Tehnologije	%Tehnologije	% Patenata	Kum. % Patenata	Područje Ispod Lorenzove krivulje		
0	0%	0%	0%	0		A
1	20%	0%	0%	0		0,14
2	40%	19,35%	19%	0,02		
3	60%	23,39%	43%	0,06		Gini
4	80%	23,39%	66%	0,11		0,29
5	100%	33,87%	100%	0,17		
		100,00%		0,36		

Izvor: : Izračuna autora

Grafički prikaz za stupanj nejednakosti prikazan je Lorenzovom krivuljom¹⁷ na kojoj se vidi da je na desnoj slici krivulja crvene boje udaljenija od plave koja predstavlja liniju jednakosti što potvrđuje tvrdnju da je distribucija patenata kontinentalne hrvatske manje jednaka.

¹⁷ Lorenzova krivulja je grafički prikaz stupnja nejednakosti, najčešće korištenog kod prikaza nejednakosti dohotka. Crvena krivulja predstavlja Lorenzovu krivulju i što je ona bliža plavoj krivulji potpune jednakosti to je nejednakost varijabli manja.

Slika 2: Lorenzova krivulja distribucije patenata jadranske i kontinentalne hrvatske



Izvor: Izračun autora

4.2.4. Sektorska struktura

Sektorska struktura, odnosi se na zaposlenost iz tri različite točke gledišta: distribucija ukupne ekonomske zaposlenosti, njena koncentracija i distribucija industrijske zaposlenosti. **Distribucija ukupne ekonomske zaposlenosti** rađena je s obzirom na broj zaposlenih na temelju nove NACE podjele¹⁸ u deset glavnih sektora, dobivenih iz baze podataka EUROSTAT. U teorijskom dijelu literature Navarro et.al (2014) navodi se kako se korišteni podatci odnose na godinu 2011. ali u priloženoj excel tablici sa opisom svake pojedine varijable navedeno je da su podatci za 2012. godinu te se iz toga ne može zaključiti o kojoj se točno godini radi. Stoga se prilikom traženja varijabli za jadransku i kontinentalnu hrvatsku o deistribuciji ukupne ekonomske zaposlenosti nasumice uzela 2012. godina. Iz baze podataka eurostata zaposlenost po starosti, ekonomskoj aktivnosti i NUTS II kategoriji¹⁹ odabran je broj zaposlenih 15 i više godina po NACE klasifikaciji u kojoj se zatim broj zaposlenih svakog sektora podijelio sa ukupnim brojem zaposlenih u svim sektorima kako bi se dobila numerička vrijednost izražena u postotcima. U *tablici 14* redom su navedeni svi dobiveni podatci za jadransku i kontinentalnu hrvatsku izračunati na opisan način.

Uz korištenje postotka distribucije ukupne ekonomske zaposlenosti, uvršten je i skupni **pokazatelj koncentracije**. To je napravljeno na način da je procijenjen prosječan udio zaposlenih u pet

¹⁸ NACE (Nomenclature statistique des activités économiques dans la Communauté européenne) je statistička klasifikacija ekonomske aktivnosti u europskoj zajednici u svrhu usporedivosti na međunarodnoj razini te je revidirana u NACE Rev.2 koja u odnosu na prethodnu verziju odražava tehnološki razvoj i strukturne promjene gospodarstva (European Commission, 2008)

¹⁹ http://appsso.eurostat.ec.europa.eu/nui/show.do?dataset=lfst_r_lfe2en2&lang=en

podsektora s najvećim brojem zaposlenih, mjereno na dvije jedinice NACE klasifikacije²⁰, u svakoj regiji. Umjesto 2011. godine, koju su koristili u svom radu Navarro et.al (2014), za hrvatske regije je korištena 2014.godina zbog nedostupnosti podataka za prethodno razdoblje. U bazi podataka EUROSTAT²¹, pronađeni su podaci o broju zaposlenih po NACE klasifikaciji na razini NUTS II regije EU. Izdvojeno je, za svaku regiju pojedinačno, prvih pet sektora s najvećim brojem zaposlenih koji je zatim podijeljen sa ukupnim brojem zaposlenih²², pojedinačno za svaku regiju. Na taj način dobije se postotak zaposlenih u top pet podsektora po NACE klasifikaciji (mjereno na dvije jedinice) na razini jadranske i kontinentalne hrvatske za 2014.godinu kao što je prikazno u slijedećoj *Tablici 4*. Obe regije broje najveći broj zaposlenih u istim podsektorima, osim u segmentu „Kopneni prijevoz i cjevovodni transport“ u kopnenoj hrvatskoj i „Smještaj“ u jadranskoj hrvatskoj. Isto tako u skoro svim podsektorima kopnena hrvatska broji veći broj zaposlenih u odnosu na jadransku osim u djelatnosti pripreme i usluživanja hrane i pića što je rezultat turističke djelatnosti. Na kraju se dijeljenjem broja zaposlenih u top pet podsektora sa ukupnim brojem zaposlenih svake regije dobije postotak sektorske koncentracije koji nam govori da je 21,59% od ukupnog broja zaposlenih kontinentalne hrvatske, zaposleno u trgovini na malo (osim trgovine motornim vozilima i motociklima), trgovini na veliko (osim trgovine motornim vozilima i motociklima), proizvodnji prehrambenih proizvoda, djelatnosti pripreme i usluživanja hrane i pića te kopnenom prijevozu i cjevovodnom transportu dok je sa 28,09% zaposlenih jadranske hrvatske koncentrirano najviše u područjima trgovine na malo, uslužnim djelatnostima pripreme i usluživanja hrane, pića i smještaja te manje u trgovini na veliko i proizvodnji prehrambenih proizvoda. Iako je sektorska koncentracija izračunata prema uputama Navara et.al (2014) postotak sektorske koncentracije jadranske i kontinentalne hrvatske su znatno veći nego kod ostalih regija EU. Tako najveći postotak sektorske koncentracije svih regija europske unije, ne uključujući hrvatsku, iznosi 16,04% (grčka regija Notio Aigaio). Nije poznato dali su izvršene određene korekcije ili podešavanje podataka ili hrvatske regije uistinu imaju najveću sektorsku koncentraciju zaposlenih u top pet podsektora u cijeloj EU.

²⁰ Prethodno navedene kategorije ekonomske aktivnosti rastavljene na podkategorije na 2 decimalne jedinice, npr. B05, B06, B07 itd.

²¹ http://appsso.eurostat.ec.europa.eu/nui/show.do?dataset=sbs_r_nuts06_r2&lang=en

²² http://appsso.eurostat.ec.europa.eu/nui/show.do?dataset=lfst_r_lfe2en2&lang=en

Prethodno navedena distribucija i koncentracija ukupne ekonomske zaposlenosti po sektorskoj strukturi nije bila dovoljna, obzirom da disagregacija industrije (osim građevinarstva) nije zadovoljavajuća zbog toga što je industrijski sektor više okrenut prema izvozu i manje ograničen lokalnim tržištem, time im omogućavajući da se više razvijaju i specijaliziraju te se zbog toga se u nastavku analizira industrijska zaposlenost.

Tablica 4: Sektorska koncentracija zaposlenosti jadranske i kontinentalne hrvatske u 2014. godini

<i>Sektorska koncentracija zaposlenosti jadranske i kontinentalne hrvatske u 2014.</i>		
Sektor	Kontinentalna hrvatska	Jadranska hrvatska
Trgovina na malo osim trgovine motornim vozilima i motociklima	78.064	51.284
Trgovina na veliko osim trgovine motornim vozilima i motociklima	48.725	18.788
Proizvodnja prehrambenih proizvoda	38.892	13.383
Djelatnosti pripreme i usluživanja hrane i pića	28.818	31.531
Kopneni prijevoz i cjevovodni transport	32.779	
Smještaj		29.080
Σ	227.278	144.066
Ukupan broj zaposlenih u svim sektorima	1.052.800	512.900
Σ zaposlenih Top 5 Podsektora	21,59%	28,09%
Σ zaposlenih u svim sektorima		

Izvor: EUROSTAT, izračun od autorice

Industrijska zaposlenost je po uzoru na OECD STAN klasifikaciju podataka podijeljena u jedanaest velikih sektora, a podatke je omogućio EUROSTAT, na poseban zahjev. Za regije jadransku i kontinentalnu hrvatsku podatci o broju zaposlenih u jedanaest velikih setora su preuzeti sa EUROSTATA²³. Svaki sektor je podijeljen sa ukupnim brojem zaposlenih svih jedanaest sektora, koji se je dobio zbrajanjem zaposlenih u svim sektorima po regijama, da bi ukupan zbroj industrijske zaposlenosti za svaku regiju iznosio 100%. Podatci su iz 2014. godine zbog ograničene dostupnosti podataka, umjesto 2011. koja se koristila u izvornom radu autora Navarra et.al (2014). Rezultati dobiveni na prethodno opisani način su redom prikazani u *Tablici 14.* Najveći broj zaposlenih je u sektoru proizvodnje prehrambenih proizvoda, pića i duhanskih proizvoda kako u obe regije hrvatske (jadranska sa 25,08% a kontinentalna 22,76%) tako i na razini regija EU (grčka regija Ipeiros 49,24%).

²³ SBS data by NUTS 2 regions and NACE Rev. 2 (from 2008 onwards)

4.2.5.Struktura poduzeća

U eurostatu su izdati podatci o **prosječnoj veličini poduzeća** na regionalnoj razini za većinu Europskih NUTS II regija, koji bi mogao poslužiti kao zamjenska varijabla za veličinu poduzeća. Međutim detaljan pregled takvih podataka otkriva da se u nekim regijama bilježe zaposlenost u poduzećima samo sa više od 10 zaposlenih, čime se podcjenjuje stvarna veličina poduzeća. Stoga, su eurostatovi regionalni podatci prilagođeni za veličinu poduzeća na nacionalnoj razini, zbog toga što potonji nema ovu pristranost (Navarro M. i dr., 2014). Međutim u eurostatovoj bazi podataka nisu dostupni podatci za jadransku i kontinentalnu hrvatsku stoga su se za procjenu veličine poduzeća uzeli podatci o broju poduzetnika (DZS, 2013) na razini NUTS II regije koji su podijeljeni sa ukupnim brojem zaposlenih u pojedinoj regiji. Na taj način se je dobio prosječan broj zaposlenih po poduzetniku, koji za kontinentalnu hrvatsku iznosi 9,7, a za jadransku regiju 5,8 zaposlenika po 1 poduzetniku dok prosjek svih regija EU iznosi 16,5 zaposlenih po poduzeću.

4.2.6.Otvorenost

Kao pokazatelj za procjenu **stupanja otvorenosti ekonomije** uzet je postotak ukupnog izvoza u BDP–u u 2009. Podatci za robnu razmjenu s inozemstvom za hrvatske regije preuzeti su sa stranica DZS-a koji su raspoređeni po županijama (DZS). Zbrojio se je ukupan iznos izvoza u € za 2010.godinu svih županija po regijama NUTS II kategorije i podijelili za ukupnim iznosom BDP-a za 2010.godinu iskazanim u €²⁴. Jadranska regija sa 16,83% ukupnog izvoza u BDP-u te kontinentalna hrvatska sa nešto više, 20,80% ukupnog izvoza u BDP-u, spadaju u regije ispod europskog prosjeka po stupnju otvorenosti ekonomije. Najotvorenija regija EU koju bilježi češka regija Střední Čechy, broji udio izvoza u ukupnom BDP-u od čak 99,81%.

4.2.7.Institucije i vrijednosti

Iako postoje mnogi institucionalni aspekti koji karakteriziraju regiju, s obzirom na dostupnost podataka korištena su tri elementa: stupanj decentralizacije, socijalni i institucionalni kapital te poduzetnički i inovativni stavovi. **Stupanj decentralizacije** teško je mjeriti, a da bi se najbliže mogao dočarati uključen je kompozitni indeks decentralizacije²⁵ razvijen od strane "BAK Basel

²⁴ http://appsso.eurostat.ec.europa.eu/nui/show.do?dataset=nama_10r_2gdp&lang=en

²⁵ Indeks decentralizacije pokazuje stupanj decentralizacije ili autonomnosti mjesne nadležnosti (regija i općina unutar zemlje). Prilikom izračuna indexa uzimaju se u obzir i kvalitativni i kvantitativni podatci, koji se sastoje od pod – indikatora administrativna (kvalitativna i kvantitativna), funkcionalna, politička i vertikalna decentralizacija

Economics"²⁶ za skupinu regija u 2009. Vrijednosti stupnja decentralizacije, donešene su na nacionalnoj razini stoga su iste za sve regije NUTS II kategorije, kreću se na skali od 0 do 100 gdje veća vrijednost indeksa predstavlja veći stupanj autonomije regija i općina u pogledu donošenja administrativnih, političkih, funkcionalnih, financijskih i drugih odluka a manja vrijednost indeksa manji stupanj autonomije. Vrijednost indeksa za hrvatsku iznosi 38 i po rangui se u odnosu na ostale 26 zemlje uključene u istraživanje nalazi na 20 –om mjestu ²⁷, iza nje zemlje sa manjim stupnjem decentralizacije su Slovačka, Litva, Latvija, Grčka, Estonija, Bugarska. Osim Vertikalne Decentralizacije (indeks=57), svi ostali pod – indikatori su ispod prosjeka Europe. Najniži rezultat bilježi u administrativnoj decentralizaciji sa rezultatom od 13 čime zauzima i zadnje mjesto od svih 26 zemalja. S druge strane Vertikalna Decentralizacija, s kojom hrvatska zauzima visoko 3.mjesto, kao pokazatelj prostorne i administrativne podijeljenosti države sama za sebe ne govori mnogo o decentralizaciji. Potrebno je pogledati i funkcionalnu (38) i političku (45) decentralizaciju. Iako hrvatska ima visoki indeks za funkcionalnu implementacijsku moć (85) financijska autonomnost je mala (40) što ograničava financijske resurse potrebne da se različiti zadatci implementiraju na regionalnoj razini (Bak Basel Economics, 2009)

Slika 3: Pod - indikatori decentralizacije za RH u 2009. godini



Izvor: BAK Basel Economics, 2009

(kvantitativni), koji sa svojim vrijednostima čini 60% indeksa decentralizacije, a financijska decentralizacija (kvalitativni i kvantitativni) 40% (BAK Basel Economics, 2009).

²⁶BAK - „Basler Arbeitsgruppe für Konjunkturforschung“, je privatna i neovisna institucija bazirana u Baselu i Zürichu, Švicarska, a od 1980. pruža analize, predviđanja i konzultantske usluge na empirijskoj i kvantitativnoj razini <https://www.bak-economics.com/ueber-uns/>.

²⁷Vrijednost se nalazi na linku: <https://aer.eu/subsidiarity-success-impact-decentralisation-economic-growth/>,

Zemlja sa najvećim indeksom decentralizacije od svih 26 zemalja uključenih u istraživanje je Švicarska (70) a prvo rangirana zemlja članica EU s najvećim stupnjem decentralizacije je Njemačka (66).

Kako bi se procijenio **socijalni i institucionalni kapital**, inkorporirana su tri indikatora. Prvi je kvaliteta institucija, osjećaj sigurnosti u regiji te poduzetničko/inovativni stav. Kvaliteta institucija mjeri se EQI indeksom²⁸ koji ocjenjuje razinu korupcije, zaštitu vladavine prava, učinkovitost i odgovornost vlade i baziran je na podacima dobivenim iz ankete s pitanjima o iskustvima građana sa javnim službama i njihovim zadovoljstvom. Podatci za RH nisu bili dostupni za 2012. godinu kao kod ostalih regija izračunate u izvornom dokumentu od strane Navarro et.al (2014) stoga su uzeti podatci za slijedeće dostupno razdoblje, 2013. godinu²⁹. Indeks sa većom vrijednošću ukazuje na veću razinu kvalitete institucija a manji indeks na veću razinu korupcije, manju učinkovitost, odgovornost vlade i zaštitu vladavine prava. Indeks kvalitete institucija za Jadransku hrvatsku iznosi -1,28 a za Kontinentalnu -1,13 što ukazuje na nisku razinu kvalitete institucija u obe regije a u jadranskoj nešto niže od kontinentalne, ali je u puno boljoj poziciji od regija s najnižom razinom kvalitete institucija na koju se pozicionirala rumunjska regija București-Ilfov sa vrijednošću indexa od -2,88 a odmah iza nje je bugarska regija Severozapaden (-2,56) te talijanska regije Campania (-2,41). S najvećim povjerenjem građana u kvalitetu institucija ocijenjena je danska regija Midtjylland sa EQI indeksom od 1,75.

Ocjena stanja **socijalne sigurnosti** u regiji provedena je kroz subjektivnu percepciju ispitanika dobivenu na temelju istraživanja European Social Survey (2010) kroz dva pitanja: „Osjećaj sigurnog kretanja samog po noći u susjedstvu“ i „Većini ljudi se može vjerovati ili nikada ne možeš biti previše oprezan“³⁰. Na prvo pitanje ispitanici su odgovarali odabirom jednog od četiri ponuđena odgovora „Jako sigurno“, „Sigurno“, „Nesigurno“ i „Jako nesigurno“.

Kako bi se dobile vrijednosti koje bi na temelju odgovora ispitanika na neki način ocijenili socijalno stanje, svakom odgovoru dane su numeričke vrijednosti koje su se zatim zbrojile i podijelile sa ukupnim brojem odgovora te na taj način dobila prosječna vrijednost koja predstavlja

²⁸ “European Quality of Government Index“ izračunati na regionalnoj razini od Charron i dr. (2012).

²⁹ EQI za hrvatsku dostupni u excel tablici na linku: <https://nicholascharron.wordpress.com/european-quality-of-government-index-eqi/>.

³⁰ Originalno: "Feeling of safety of walking alone in local area after dark" i "Most people can be trusted or you can't be too careful".

proxy varijablu ocjene stanja socijalne sigurnosti. Na primjeru pitanja „Osjećaj sigurnog kretanja samog po noći u susjedstvu“ odgovorima su dane numeričke vrijednosti na skali od 1 – 4, gdje je vrijednost 1 = „Jako sigurno“, 2 = „Sigurno“, 3 = „Nesigurno“, 4 = „Jako nesigurno“. S obzirom da je u vrijeme provođenja istraživanja hrvatska bila podijeljena na tri kategorije NUTS 2 razine, dobiveni odgovori za sjeverozapadnu i panonsku, hrvatsku su zbrojeni.

Tablica 5: "Osjećaj sigurnog kretanja samog po noći u susjedstvu" od 1 - 4 za jadransku i kontinentalnu hrvatsku

<i>„Osjećaj sigurnog kretanja samog po noći u susjedstvu“</i>									
JADRANSKA HRVATSKA				KONTINENTALNA HRVATSKA					
				<i>Panonska hrvatska</i>		<i>Sjeverozapadna hrvatska</i>			
ODGOVOR	NUMERIRANI ODGOVORI	BROJ ODGOVORA	A*B1	BROJ ODGOVORA	A*B2	BROJ ODGOVORA	A*B3	B2+B3	(A*B2)+(A*B3)
	A	B1		B2		B3			
„Jako sigurno“	1	186	186	201	201	252	252	453	453
„Sigurno“	2	279	558	223	446	283	566	506	1012
„Nesigurno“	3	43	129	32	96	73	219	105	315
„Jako nesigurno“	4	9	36	15	60	18	72	33	132
Σ		517	909	471	803	626	1109	1097	1912
$\frac{\Sigma(A \cdot B1)}{\Sigma B1} = 1,76$				$\frac{\Sigma(A \cdot B2) + (A \cdot B3)}{\Sigma B2 + B3} = 1,74$					

Izvor: Open ESS Round 5 (2010), izračun autora

Iz *Tablice 5* je vidljivo da su ispitanici prema kriteriju „Osjećaj sigurnog kretanja samog po noći u susjedstvu“ ocijenili jadransku i kontinentalnu hrvatsku jednako sigurnim regijama, s obzirom da prosječne vrijednosti zbrojenih odgovora 1,76 i 1,74 ulaze u interval između 1=„Jako sigurno“ i 2=„Sigurno“ naginjući više prema 2. Najveći osjećaj sigurnosti imaju ispitanici talijanske regije Basilicata (1,40) dok u suprotnom najmanje sigurnim se osjećaju ispitanici grčke regije Sterea Elada (2,84).

Kod druge varijable ispitanici odgovaraju na skali od 0 do 10 gdje vrijednosti bliže 0 označavaju tvrdnju „Ne možeš biti previše oprezan“ a vrijednosti bliže 10 „Većini ljude se može vjerovati“. Odgovorima su dane numeričke vrijednosti od 0 – 10. Na isti način kao i prethodno pomnoženi su broj odgovorenenih tvrdnji sa pridodanim numeričkim vrijednostima a njihova suma je podijeljena sa ukupnim brojem odgovora. Na temelju rezultata prikazanih na slici 3 vidljivo je da su stavovi građana po pitanju kriterija „Većini ljudi se može vjerovati ili nikada ne možeš biti previše oprezan“ za jadransku i kontinentalnu hrvatsku jako slični. Vrijednosti za obe regije se nalaze po sredini skale od 0 – 10 sa vrijednostima 4.27 i 4.55 naginjući malo više odgovoru da se nemože

biti previše oprezan ali opet nije kao u slučaju grčke regije Dytiki Makedonia čija vrijednost iznosi 1.96, dok najveće povjerenje prema ljudima osjećaju ispitanici danske regije Hovedstaden sa vrijednošću od 7.00.

Tablica 6: "Većini ljudi se može vjerovati ili nikada ne možeš biti previše oprezan" od 0 - 10 za jadransku i kontinentalnu hrvatsku

„Većini ljudi se može vjerovati ili nikada ne možeš biti previše oprezan“									
		JADRANSKA HRVATSKA		KONTINENTALNA HRVATSKA					
				Panonska hrvatska		Sjeverozapadna hrvatska			
ODGOVOR	NUMERIRANI ODGOVORI	BROJ ODGOVORA	A*B1	BROJ ODGOVORA	A*B2	BROJ ODGOVORA	A*B3	B2+B3	(A*B2)/(A*B3)
	A	B1		B2		B3			
„Ne možeš biti previše oprezan“ ³¹	0	32	0	50	0	28	252	78	252
1	1	27	27	22	22	25	25	47	47
2	2	51	102	38	76	50	100	88	176
3	3	75	225	56	168	80	240	136	408
4	4	77	308	50	200	54	253	104	453
5	5	125	625	117	585	125	625	242	1210
6	6	59	354	58	348	66	396	124	744
7	7	42	294	44	308	92	644	136	952
8	8	22	176	32	256	90	254	122	510
9	9	7	63	5	45	7	63	12	108
„Većini ljudi se može vjerovati“ ³²	10	6	60	9	90	8	80	17	170
Σ		523	2234	481	2098	625	2932	1106	5030
		$\frac{\Sigma(A*B1)}{\Sigma B1} = 4,27$		$\frac{\Sigma(A*B2)+A*B3}{\Sigma B2+B3} = 4,55$					

Izvor: Open ESS Round 5 (2010), izračun autora

Na temelju istog upitnika mjeren je i element poduzetničko - inovativni stavovi građana kroz pitanja: „Važno je smišljati nove ideje i biti kreativan“ i „Važno je isprobati nove i različite stvari u životu“³¹. Ispitanici su na oba pitanja odgovarali odabirom jednog od četiri ponuđena odgovora koji su numerirani na skali od 1 – 6. 1 = „Vrlo slično meni“, 2 = „Slično meni“, 3 = „Nešto poput mene“ i 4 = „Malo poput mene“, 5 = „Ne poput mene“, 6 = „Uopće ne poput mene“³². Numeričke vrijednosti brojeva su zbrajane i podijeljene sa ukupnim brojem odgovora. Vrijednosti bliže nuli podrazumijevaju poistovještivnje sa stavom o važnosti smišljanja novih ideja i kreativnošću i obratno.

Iz *Tablice 7* opet je vidljivo da su stavovi građana za obe regije jako slični ali isto tako da građani i jadranske i kontinentalne hrvatske nisu toliko okrenuti smišljanju novih i kreativnih ideja kao što su građani talijanske regije Friuli – Venezia Giulia koja bilježi najniži rezultat (1,46) što ih čini

³¹ Originalno: "Important to think new ideas and being creative" i "Important to try new and different things in life"

³² Originalno: "Very much like me", "Like me", "Somewhat like me" i "A little like me", "Not like me", "Not like me at all".

najbliže odgovoru „Vrlo slično meni“. S druge strane građani španjolske regije La Rioja (3,83) su u odnosu na građane ostalih regija najmanje okrenuti inovativnošću novih ideja i kreativnošću.

Tablica 7: "Važno je smišljati nove ideje i biti kreativan" za jadransku i kontinentalnu regiju

<i>„Važno je smišljati nove ideje i biti kreativan“</i>									
JADRANSKA			KONTINENTALNA HRVATSKA						
ODGOVOR	NUMERIRANI ODGOVORI	BROJ ODGOVORA	A*B1	Panonska hrvatska		Sjeverozapadna hrvatska		B2+B3	(A*B2)+(A*B3)
				BROJ ODGOVORA	A*B2	BROJ ODGOVORA	A*B3		
	A	B1		B2		B3			
„Vrlo slično meni“	1	71	71	62	62	145	252	207	314
„Slično meni“	2	144	288	145	290	192	384	337	674
„Nešto poput mene“	3	129	387	107	321	126	378	233	699
„Malo poput mene“	4	89	356	73	292	93	372	166	664
„Ne poput mene“	5	50	250	57	285	54	252	111	537
„Uopće ne poput mene“	6	19	114	25	150	12	72	37	222
Σ		517	1466	469	1400	622	1386	1091	3110
		$\frac{\Sigma(A*B1)}{\Sigma B1} = 2,84$		$\frac{\Sigma(A*B2)+(A*B3)}{\Sigma B2+B3} = 2,85$					

Izvor: Open ESS Round 5 (2010), izračun autora

S tvrdnjom da je važno isprobati nove i različite stvari u životu najveći broj ispitanika kontinentalne hrvatske (3,24) se poistovjećuje sa odgovorom „Nešto poput mene“, a ispitanici jadranske hrvatske, sa rezultatom (3,66), iskazuju svoje stajalište „Malo poput mene“. Ispitanici portugalske regije Algarve sa rezultatom od 4,30 ne misle da je važno isprobati nove i različite stvari u životu dok najveći broj ispitanika koji se slaže s tvrdnjom pripada talijanskoj regiji Sardegna (2,22).

Tablica 8: "Važno je isprobavati nove i različite stvari u životu" za jadransku i kontinentalnu hrvatsku

<i>„Važno je isprobati nove i različite stvari u životu“</i>									
JADRANSKA			KONTINENTALNA HRVATSKA						
ODGOVOR	NUMERIRANI ODGOVORI	BROJ ODGOVORA	A*B1	Panonska hrvatska		Sjeverozapadna hrvatska		B2+B3	(A*B2)+(A*B3)
				BROJ ODGOVORA	A*B2	BROJ ODGOVORA	A*B3		
	A	B1		B2		B3			
„Vrlo slično meni“	1	45	45	52	52	82	252	134	304
„Slično meni“	2	69	138	93	186	118	236	211	422
„Nešto poput mene“	3	108	324	101	303	122	366	223	669
„Malo poput mene“	4	112	448	87	348	139	556	226	904
„Ne poput mene“	5	125	625	88	440	118	252	206	692
„Uopće ne poput mene“	6	42	252	47	282	43	258	90	540
Σ		501	1832	468	1611	622	1410	1090	3531
		$\frac{\Sigma(A*B1)}{\Sigma B1} = 3,66$		$\frac{\Sigma(A*B2)+(A*B3)}{\Sigma B2+B3} = 3,24$					

Izvor: Open ESS Round 5 (2010), izračun autora

Ovako izračunati set varijabli za jadransku i kontinentalnu hrvatsku, koji se mogu vidjeti u *Tablici 14* u prilogima, pridružuju se vrijednostima varijabli ostalih regija dodanih od strane autora Navarra et.al (2014). U cijelom setu od 205 regija pridružuju im se jadranska i kontinentalna koje dalje podliježu daljnim metodološkim procesima i analizama prikazanim u nastavku. U prvome djelu idućega poglavlja opisana je metodologija istraživanja kojom će se raditi a u drugom dijelu analiza rezultata i dobivenih referentnih regija te njihova usporedba po varijablama.

5. EMPIRIJSKO ISTRAŽIVANJE ODREĐIVANJA HOMOGENOSTI REGIJA

5.1. Metodologija istraživanja

Prethodno opsežno definirane varijable sa njihovim vrijednostima utvrđenim od strane Navarra et.al (2014) i novim pronađenim vrijednostima od strane autorica temelj su daljnje obrade i analize. Istraživanje na kojem se temelji ovaj rad provedeno je na primjeru regije Baskije u određivanju referentnih regija za primjenu benchmarkinga i predstavlja primjer u daljnjoj obradi podataka i provođenju procesa analize. U ovome radu pokušat će se slijediti istu metodologiju kao u temeljnom istraživanju, koliko god to uvjeti dopuštaju a sva odstupanja rezultat su nemogućnosti provedbe. S obzirom da je glavna svrha, kako navedenog poglavlja tako i cjelokupnog istraživanja, dati odgovor na pitanja u kojoj mjeri su regije hrvatske homogene za provođenje jedinstvene strategije i dali postoje neke druge NUTS II regije europske unije sličnih strukturnih karakteristika, potrebno je konstruirati matricu udaljenosti koja mjeri udaljenost između jadranske, kontinentalne i ostalih regija. U nastavku su opisani svi koraci, za dobivanje matrice udaljenosti između regija, a provedeni su pomoću statističkih programa SPSS i Excel.

i. Standardizacija

Prvo je **radi usporedbe** potrebno podatke prikupljene u prethodnom poglavlju, za jadransku i kontinentalnu hrvatska, i podatke preuzete od Navarra, M. i dr. (2014) za ostale europske regije transformirati u varijable koje dijele iste mjerne jedinice, s obzirom da su 44 varijable, kojima se definiraju strukturne karakteristike, definirane različitim jedinicama. U izvornome radu taj problem su autori riješili tako da su prikupljene sirove podatke korigirali za outliere, asimetričnost i zaobljenost a zatim ih normalizirali min – max metodom. Korekcija za outliere provodi se u tri faze, s tim da outlieri korigirani u prvoj fazi ne podilaze daljnjoj korekciji. Stoga outliere koji nisu ispraviljeni u prve dvije faze podliježu daljnjoj korekciji u zadnjoj tzv. Yeo – Johnson transformaciji³³ koja se međutim može izvesti samo u programu zvanom Arc (Sanford Weisberg, 2001). S obzirom na kompliciranost zadnjeg postupka napušta se ovakva metoda transformacije

³³ Najsličnije su transformacijama Cox – Box, a za razliku od njih mogu uključivati i negativne vrijednosti ali s obzirom da se nije našao način za primjenu u korištenim statističkim programima korištena je druga metoda.

izvornih varijabli i umjesto toga se varijable standardiziraju Z – vrijednostima stavljanjem vrijednosti aritmetičke sredine na nulu a standardne devijacije na jedan.

ii. Koncentracija varijabli

Standardizirane vrijednosti iz prethodnog poglavlja podliježu daljnjem postupku a to je **koncentracija elemenata**. Ova metoda obuhvaća sažimanje ukupnog broja varijabli tako da umjesto početne 44 komponente nakon koncentracije varijabli nastavljamo sa njih 21³⁴. To se radi na način da se u slučaju korištenja jedne varijable onda ta varijabla i zadržava. Ako je jedan element mjeran dvjema varijablama, kao što je u slučaju „Starenje“ i „Poduzetničko inovativni stavovi“, onda se računa njihova aritmetička sredina. Međutim ako je jedan element mjeran dvjema ili više komponentama, kao što su „Tehnološka distribucija patenata“, „Ekonomska sektorska distribucija“, „Industrijska sektorska struktura“ te „Socijalni i institucionalni kapital“ tada se provodi analiza glavnih komponenti³⁵ kojom se zadržava minimalan broj komponenti potrebne da objasne većinu varijabilnosti podataka. Novoformirane komponente prikazane su u *Tablici 13*.

iii. Određivanje i dodjeljivanje faktora vrijednosti (pondera)

Određivanje faktora vrijednosti za svaku varijablu moguće je napraviti na više načina. U svome radu Navarro et.al su to napravili na temelju faktora opterećenja glavnih komponenti izvodeći jednu PCA koja uključuje sve 22 varijable³⁶. U ovom slučaju težine za svaku komponentu su izračunate agregiranjem kvadratnih faktorskih opterećenja u svakoj od zadržanih varijabli, koje su pomnožene sa postotkom varijance koju svaka komponenta objašnjava. U *Tablici 13* su prikazani ponderi izračunati od strane Navarra et. al (2014) ali i korigirani za postotak varijable koja fali s obzirom da u ovom u odnosu na izvorno istraživanje fali jedna varijabla. Korigirani ponderi dobiveni su na slijedeći način. Suma y za svih 21 komponenta iznosi 100%.

$$y = x + (x \times p)$$

y = korigirana vrijednost pondera promatrane varijable

³⁴ U radu Navarro et.al (2014) nakon koncentracije dobivene su 22 varijable ali s obzirom da smo morali izbaciti varijablu „Multimodalna pristupačnost“ u postupku prikupljanja podata i ovdje će biti jedna komponenta manje.

³⁵ Principal Component Analysis (PCA) je alat za redukciju dimenzije podataka koji se koristi za smanjivanje velikog broja podataka bez umanjivanja informacija koje sadrži izvorni set podataka.

³⁶ Osim toga moguće je izvesti PCA za svaku od sedam dimenzija na koje su varijable podijeljene ili za četiri makro dimenzije, koje su određene s obzirom na frekvenciju kojom se sedam elemenata spominje u literaturi, tako npr. u prvu makro dimenziju ulaze najcitiranije od sedam dimenzija itd. (Navarro M. i dr., 2014)

x = vrijednost pondera promatrane (22) varijable
p = vrijednost pondera (1) eliminirane varijable³⁷

Nakon što su se odredile korigirane vrijednosti pondera, slijedi njihovo dodavanje varijablama množenjem sa svakom od komponenti za koju je ponder dodijeljen.

iv. Agregacija

Nakon prva tri postupka dobiju se koncentrirane standardizirane komponente sa dodijeljenim faktorima vrijednosti a u nastavku slijedi njihova agregacija kako bi se kalkulirala matrica međusobne udaljenosti regija. Postoje različite alternative za agregaciju komponenti kako bi se kalkulirala matrica udaljenosti a Navarro et. al (2014) se u svom radu fokusirao na tzv. Aditivnu kvadratvnu agregaciju³⁸, kojom se računa ukupna udaljenost između dviju regija. Izraz u zagradi označava udaljenost udaljenost dviju regija jedne komponente, a sumiranjem svih komponenti ukupna udaljenost dviju regija. Vrijednost dodijeljenog pondera m_j se je već pribrojao u prethodnom koraku.

$$d(i, i^*) = \sum_{j=1}^k m_j (x_{ij} - x_{i^*j})$$

m_j = ponder vrijednosti dodijeljenoj varijabli
 j = varijabla,
 i = prva regija,
 i^* = druga regija

Nakon odlučivanja kojom funkcijom će se izračunati matrica udaljenosti u nastavku slijedi proces dobivanja matrice udaljenosti te dobivanja referentnih regija cluster i individualnim pristupom.

v. Dobivanje matrice udaljenosti

Računanjem ukupne udaljenosti između jedne NUTS II regije i ostalih, dobivamo red udaljenosti jedne regije sa svim ostalim regijama a računanjem postupka za sve regije, matricu udaljenosti. U programskom paketu SPSS može se izračunati matrica udaljenosti upotrebom metode „Hierarchical Cluster Analysis“³⁹ u kojoj se pod opcijama odabira mjere za računanje intervala u

³⁷ U ovom slučaju iznos pondera eliminirane varijable je 5,49%, stoga je vrijednost $p = 0,0549$.

³⁸ Additive quadratic aggregation

³⁹ Dva osnovna pristupa klaster analizi su hijerarhijska i nehijerarhijska, U programskom paketu SPSS – u moguće je izvršiti „Hijerarhijsku“, „Two Step“ i tzv. „K – means“ analizu.

padajućem izborniku nalazi „Squared Euclidean distance“⁴⁰, čija formula je ista kao Aritmetička kvadratna agregacija ali bez množenja sa ponderom. Zato se prilikom izbora varijabli na kojima će se vršiti klaster analiza uzimaju koncentrirane standardizirane komponente sa dodijeljenim faktorima vrijednosti. Dobivena tzv. „Proximity matrix“⁴¹, prikazuje koliko se promatrani objekti razlikuju međusobno odnosno u ovom slučaju koliko su neke regije različite od drugih. Numeričke vrijednosti matrice izražavaju koeficijent različitosti i što je manja njegova vrijednost u to je manja različitost među regijama.

vi. Klaster pristup

Jedna od tipologija prema kojoj se mogu utvrditi regije sa sličnim strukturnim karakteristikama je klaster analiza za identificiranje grupe regija koje dijele neka zajednička svojstva u ovom slučaju strukturne karakteristike. Koju klaster analizu je Navarro et.al (2014) koristio u svom istraživanju nije poznato jer nije navedeno stoga će se rezultati prikazati primjenom hijerarhijske i nehijerarhijske klaster analize u programskom paketu SPSS.

Glavna komponenta koju čini hijerarhijska klaster analiza je dendogram, koji nalik stablu povezuje klastere na aglomerativni ili divizijski način. U aglomerativnom se podrazumijeva da su svi analizirajući objekti savršeno homogeni i na početku ima onoliko klastera koliko ima objekata. Zatim se na temelju matrice sličnosti najbližiji objekti povezuju u matricu a ukupan broj klastera se smanjuje za jedan. Taj postupak se ponavlja sve dok se svi objekti ne nađu unutar jednog klastera. Divizijski način ide u obratnom smjeru podrazumijevajući da na početku imamo jedan klaster, a postupak završava na onoliko klastera koliko ima promatranih objekata. Postupak pripajanja u klastere ovisi o odabiru metode klaster analize, a među najčešće korištenima su metoda najbližeg susjeda, metoda najudaljenijeg susjeda, metoda prosječne povezanosti, metoda centroida, Wardova metoda i dr. Nehijerarhijske za razliku od prethodne podrazumijeva odabir broj klastera, u koje se na temelju nehijerarhijskih algoritama analize, razvrstavaju objekti unaprijed. Najpoznatiji algoritam analize kod nehijerarhijskih metoda je *k – srednjih vrijednosti*⁴² (Devčić i dr., 2012) kojom se u iste klastere svrstavaju objekti po principu optimalne prosječne udaljenosti.

⁴⁰Kvadrirana Euklidijska udaljenost koja se računa formulom: $d(i, i^*) = \sum_{j=1}^k (x_{ij} - x_{i^*j})$

⁴¹ U doslovnom prijevodu matrica neposredne blizine.

⁴² Eng. k – means metoda

vii. Individualni pristup

Klaster analiza ne pruža direktnu vizualizaciju udaljenosti između određene regije i regija smještenih u drugu kategoriju. Stoga nam tu uvelike pomaže matrica udaljenosti na temelju koje je moguće vidjeti redoslijedom koje regije su najbliže određenoj regiji a koje najudaljenije. U ovom primjeru detaljno će se izabrati pet regija koje bilježe najmanju udaljenost koeficienta različitosti od regija jadranske i kontinentalne hrvatske.

5.2. Rezultati istraživanja


5.2.1. Hijerarhijska klaster metoda

U programskom paketu SPSS pod „Hierarchical Cluster Analysis“ udaljenost između najbližijih regija može se izmjeriti odabirom klaster metode „Nearest neighbor“, a intervalnom metodom „Squared Euclidean distance“ udaljenosti. Najčešće korišteni grafički prikaz za ovu klaster analizu je dendrogram koji prikazuje raspored klastera nastalih hijerarhijskim spajanjem regija u nove klastere i sa već prije određenim klasterima. Mana kod dendrograma je što nije pogodan prikazivanja veće podatke pa ga je i teško zbog toga isčitati stoga je u nastavku izrezan samo dio dendrograma koji prikazuje klasteriziranje jadranske i kontinentalne hrvatske.

Ono što je prikazano na dendrogramu je samo jedna desetina cijele slike i to zadnji kraj grafa. Fali prikaz klasteriziranja preostalih 180 regija. Grane dendrograma, koje su pravokutnog oblika, koje se nalaze u tom dijelu dendrograma su manje veličine, tako da se na ovom dijelu slike nalaze najveći po dužini dijelovi grana. Sličnost između dvije regije je prezentirana dužinom grana, dakle što su grane pravokutnog oblika bliže lijevoj strani grafa to su sličnije jedna drugoj. Iz dendrograma je vidljivo da jadranska i kontinentalna regija, koje se nalaze na trećem i četvrtom mjestu slike gledajući odozdo, po dužini grane pravokutnog oblika, naginju više prema lijevom kraju dendrograma što nam govori da ove dvije regije i nisu toliko slične jedna drugoj, te da ima puno više ostalih regija europske unije koje su međusobno slične. Ipak one se prve međusobno uparuju u klaster prije nego sa bilo kojom drugom regijom. To nam govori i tablica aglomerativnog rasporeda⁴³ koja prikazuje da su se jadranska i kontinentalna hrvatska uparile u klaster tek 201 po redu, od mogućih 206, po koeficientu aglomeracije 583,982. To znači pak da za jadransku hrvatsku

⁴³ Agglomeration schedule

Slika 4: Dendrogram dobiven hijerarhijskom klaster analizom u SPSS-u



Izvor: Izračun autora

ne postoji niti jedna druga regija koja joj je po svojim strukturnim karakteristikama sličnija od kontinentalne regije i obratno. Ovi koeficienti su ujedno i mjere udaljenosti izražene u matrici udaljenosti (samo za prvi par spajanja), u tu se vidi koje su negativne strane hijerarhijske analize. Pošto svi moraju biti pripojeni u klaster, nakon spajanja jadranske regije i kontinentalne regije u klaster, njihov klaster se dalje spaja sa austrijskom regijom AT11, što je vidljivo iz aglomeracijskom rasporedu i koeficientu 683,646 time aludirajući da su regije jako bliske ali na matrici udaljenosti koeficient sličnosti nam govori da su one su za tri (kontinentalna) do pet (jadranska) puta dalje jedna od drugih. Dakle koeficienti iskazani u aglomeracijskoj tablici su precizni samo kada se radi o prvom klaster spajanju ali za svako daljnje spajanje dviju ili više klaster grupa, nije precizan, te stoga uvijek treba pogledati matricu udaljenosti i njezin koeficient sličnosti. Jer dendrogram nam samo govori da je jedna regija ili klaster regija **sličnija** sa drugom regijom ili klasterom regija u odnosu treću regiju ili klaster regija. U slijedećem dijelu prikazane su referentne regije odabrane na temelju individualnog pristupa pomoću matrice udaljenosti.

5.2.2. Individualni pristup

Na temelju matrice udaljenosti i odabirom njezinih vrijednosti koje pokazuju koliko se dvije regije razlikuju jedna od druge. Pogledom na brojeve retka regije jadranske i kontinentalne hrvatske isčitavaju se one regije koje imaju manju vrijednost jer to znači da se one manje razlikuju. U nastavku je prikazan popis regija jadranske i kontinentalne hrvatske i njihovih referentnih regija te njihove vrijednosti koeficienta različitosti.

Tablica 9: Referentne regije jadranske i kontinentalne hrvatske odabrane na temelju individualnog pristupa

Jadranska hrvatska			Kontinentalna hrvatska		
Rb.	Referentna regija	Koeficient različitosti	Rb.	Referentna regija	Koeficient različitosti
1	Kontinentalna hrvatska (HR)	583,982	1	Jadranska hrvatska (HR)	583,982
2	Kriti (EL)	1180,456	2	Nord-Pas-De-Calais (FR)	683,646
3	Nord-Pas-De-Calais (FR)	1189,823	3	Kentriki Makedonia (GR)	717,183
4	Notio Aigaio (GR)	1389,774	4	Basse-Normandie (FR)	742,913
5	Basse-Normandie (FR)	1548,499	5	Kriti (EL)	802,793
6	Northem Ireland (UK)	1633,165	6	Malopolskie (PL)	825,652
7	Kentriki Makedonia (GR)	1682,179	7	Wielkopolskie (PL)	828,532
8	Wielkopolskie (PL)	1691,286	8	Attiki (GR)	877,072
9	Voreio Aigaio (GR)	1743,619	9	Northem Ireland (UK)	891,521
10	Trentino-Alto Adige/Südtirol (IT)	1744,459	10	Mazowieckie (PL)	903,448

Izvor: Izračun autora

Iz tablice se može vidjeti da su jadranska i kontinentalna hrvatska jedna drugoj najbliže regije, u istom koeficientu naravno, jer matrica ide u simetričnom smjeru. Gledajući na sami iznos koeficienta (583.98), može se reći da je puno viši nego kod ostalih regija u matrici udaljenosti. Npr. dvije najslbližije regije europske unije imaju koeficient od 43.087 što je i više nego deseterostuko manja nego u slučaju hrvatskih regija. Također se može vidjeti da i jadranska i kontinentalna hrvatska od deset referentnih regija dijele skoro iste regije, samo su na drugačijim rednim položajima. U nastavku će se analizirati vrijednosti varijabli triju referentnih regija iz različitih država.

Sto se tiče geo – demografskih uvjeta vidimo da hrvatska dijeli u nekim segmentima slične karakteristike kao i njezine referentne regije. Vidimo da se uglavnom radi naravno o manjim regijama, što se tiče broja stanovništva regije, u odnosu na nacionalnu razinu jer tako

npr. francuska regija Nord Pas De Calais ima stanovnika koliko i cijela hrvatska ali na nacionalnoj razini spada u manje regije. Po broju mlađeg i starijeg stanovništva, jadranska i kontinentalna hrvatska sa grčkom regijom dijele isti smjer kretanja, odnosno više stanovništva starijih od 65 a manje mlađih od 15, u obratnom smjeru ide francuska regija Nord Pas De Calais i poljska regija. U svim referentnim regijama, osim francuske Nord Pas De Calais, postotak stanovništva koji živi u urbanim i tzv. zonama dnevne migracije je na sličnoj razini samo francuska iskače sa 82,29%. Obe hrvatske regije, a jadranska malo više, se ističu po postotku obrazovanja stanovništva.

Tablica 10: Usporedba hrvatskih regija s referentnim regijama u geo demografskoj, obrazovnoj i tehnološkoj dimenziji

DIMENZIJA	VARIJABLE	Jadranska	Kontinentalna	Nord Pas De Calais (FR)	Kentriki Makedonisa (GR)	Malopolskie (PL)
1. Geo - demografski	Ukupna populacija	1 413 426	2 876 431	4 046 720	1 955 018	3 341 747
	Populacija >=65	18,32%	17,44%	14,42%	19,56%	13,69%
	Populacija <15	14,80%	15,50%	21,52%	15,81%	17,22%
	Urbanizacija	55,73%	53,79%	82,29%	54,15%	64,80%
2. Razina obrazovanja	Razina obrazovanja	85,20%	78,10%	67,50%	64,60%	91,20%
3. Tehnološka distribucija (patenti)	Biotehnologija	19,35%	13,01%	29,43%	8,82%	10,24%
	ICT	23,39%	44,89%	34,64%	64,80%	58,90%
	Nanotehnologija	0,00%	0,00%	0,71%	0,00%	2,89%
	Medicinska tehnologija	33,87%	1,76%	16,75%	3,03%	8,16%
	Farmacija	23,39%	40,34%	18,47%	23,35%	19,81%
Tehnološka koncentracija (patenti)	Gini indeks od 5 područja	28,71%	51,34%	32,22%	59,96%	49,47%

Izvor: Navarro et. al i izračun autora

Što se tiče distribucije patenata na razini od 2009. – 2013. Jadranska hrvatska se ističe po broju prijavljenih patenata u području medicinske tehnologije a kontinentalna u području farmacije. Francuska regija Basse Normandie prednjači u broju prijavljenih patenata iz područja ICT – a dok je zajedničko svima nulta razina iz područja nanotehnologije, što i ne čudi s obzirom da se tu koriste tehnološki naprednije tehnologije. O sličnostima regija u tehnološkoj distribuciji najviše se može isčitati iz Gini indexa za 5 tehnoloških područja, vidimo da kontinentalna hrvatska dijeli najbližnju

vrijednost sa ostalim regijama, negdje oko 50%, dok je jadranska hrvatska daleko ispod te razine, ali uzimajući u obzir koeficijent različitosti sve ove regije iako spadaju u referentna područja jadranske hrvatske su manje slične sa njom, i to za čak do dvostruko ili trostruko manje. U slijedećem grafu vidjet ćemo dali je obrazac ponašanja isti.

Tablica 11: Usporedba hrvatskih regija s referentnim regijama u sektorskoj dimenziji

DIMENZIJA	VARIJABLE	Jadranska	Kontinentalna	Nord Pas De Calais (FR)	Kentriki Makedonisa (GR)	Malopolskie (PL)
4. Sektorska struktura: Ekonomska sektorska distribucija	Poljoprivreda, šumarstvo i ribolov (A)	6,69%	14,86%	1,11	13,52%	13,12%
	Industrija (osim građ.) (B-E)	18,71%	21,96%	16,86%	11,87%	21,64%
	Građevinarstvo (F)	6,25%	7,30%	6,83%	4,20%	9,41%
	Trgovina na veliko i malo, transport i sl. (B-I)	35,15%	22,76%	22,21%	30,51%	22,88%
	Informacije i komunikacije (J)	1,61%	2,64%	1,79%	1,30%	2,22%
	Financijske i osiguravajuće aktivnosti (K)	2,68%	2,44%	2,92%	2,59%	2,34%
	Nekretnine (L)	0,36%	0,13%	1,00%	0,16%	0,55%
	Profesionalne, znanstvene i tehničke aktivnosti (M-N)	5,88%	5,90%	7,38%	8,12%	6,31%
	Javna administracija (O-Q)	18,45%	18,02%	34,75%	23,31%	18,45%
	Umjestnost, zabava i rekreacija (R-U)	4,11%	3,81%	4,95%	4,42%	3,02%
Sektorska koncentracija	Top 5 podsektora	28,09%	21,59%	15,63%	11,53%	9,92%
4. Sektorska struktura : Industrijska sektorska struktura	Rudarstvo i vađenje (05-09)	6,04%	4,89%	10,19%	8,25%	16,51%
	Hrana, piće, duhan (10-12)	25,08%	22,76%	19,46%	29,53%	15,29%
	Tekstil, odjeća i koža (13-15)	4,38%	14,13%	4,11%	9,58%	6,90%
	Drvo, papir i tisak (16-18)	7,58%	11,72%	6,91%	7,53%	10,17%
	Kemija, Farmacija, guma, plastika i rafinirana nafta (19-22)	6,34%	8,49%	14,09%	6,86%	8,41%
	Ne metalni, mineralni proizvodi (23)	6,77%	3,76%	6,17%	4,65%	3,63%
	Osnovni metali i metalni proizvodi (24-25)	14,22%	12,46%	13,86%	11,36%	15,57%
	Električna, elektronska, kompjuterska i optička oprema (26-27)	2,80%	6,98%	2,31%	3,44%	5,18%
	Mašinerija (28)	2,48%	4,89%	3,33%	4,34%	2,90%
	Transportna oprema (29-30)	11,41%	1,62%	10,91%	1,42%	7,45%
	Ostala proizvodnja (31-33)	12,91%	8,29%	8,66%	13,04%	7,93%

Izvor : Navarro et. al (2014) i izračun autora

Pogledom na dimenziju ekonomske sektorske strukture među hrvatskim regijama i regijama EU uočena je prilično slična raspodjela zaposlenih po NACE klasifikaciji, najviše se ističe razlika kod francuske regije gdje ima samo oko 1 % zaposlenih u poljoprivredi, šumarstvu i ribolovu. Taj postotak zaposlenih koji fali se je raspodijelio u javnoj administraciji koja u toj regiji broji najveći broj zaposlenih. Sto se tiče broja zaposlenih u top 5 podsektora, hrvatske regije tu iskaču ali to je već napomenuto u prethodnom poglavlju da nije jasno kako su se dobili podatci za ostale regije te da možda nije korištena ista metoda. Sto se tiče strukture industrijske zaposlenosti najviše se razlike može uvidjeti u sektoru rudarstva te hrane i pića, gdje mediteranske regije i francuska imaju puno više zaposlenih u turističkom sektoru a malo u rudarstvu dok je kod poljske u obrnutom smjeru.

Kod usporedbe varijabli u zadnjem segmentu elemenata regije dijele sličnu strukturu a razlike su vidljive kod prosječne veličine poduzeća gdje se ističe francuska regija sa prosječnim brojem zaposlenih od 21. Ostale razlike mogu se vidjeti kod Grčke regije Makedonija koja je najmanje otvorena za trgovinu, francuska regija ima najbolju kvalitetu institucija ali skupa sa grčkom regijom zastupljen je najmanji osjećaj sigurnosti.

Tablica 12: Usporedba hrvatskih regija s referentnim regijama u dimenzijama veličine poduzeća, otvorenosti, decentralizacije te institucionalnih i poduzetničkih vrijednosti

DIMENZIJA	VARIJABLE	Jadranska	Kontinentalna	Nord Pas De Calais (FR)	Kentriki Makedonisa (GR)	Malopolskie (PL)
Veličina poduzeća	Prosječna veličina poduzeća	5,8	9,7	21,8	4,0	11,2
Trgovinska otvorenost	Ukupan izvoz (%BDP-a)	16,83%	20,80%	28,40%	6,07%	26,54%
Višedimenzijska država	Decentralizacija	38	38	42	31	48
Socijalni i institucionalni kapital	Kvaliteta institucija	-1,28	-1,13	0,52	-1,43	-0,88
	Osjećaj sigurnosti hodanja sam u lokalnom području po mraku	1,76	1,74	2,31	2,40	1,92
	Većini ljudi se može vjerovati ili nikad ne možeš biti pre siguran	4,27	4,56	3,66	4,17	4,29
Poduzetnički/inovativan stav	Važno je smišljati nove ideje i biti kreativan	2,92	2,77	2,67	2,34	2,90
	Važno je probati nove i drugačije stvari u životu	3,66	3,39	3,00	2,74	3,10

Izvor : Navarro, M. i dr. (2014) i izračun autora

U nastavku je prikazan postupak klasteriziranja jadranske i kontinentalne regije primjenom nehijerarhijske klaster metode primjenom algoritama k – srednjih vrijednosti.

5.2.3. Nehijerarhijska klaster metoda : k - srednjih vrijednosti

K – srednjih vrijednosti klaster analizom u programskom paketu SPSS, moguće je također izvršiti klasteriranje regija jednakih strukturnih uvjeta. Osnovna razlika je da se unaprijed određuje broj klastera u koje se želi regije svrstavati i kao varijable uzete su standardizirane vrijednosti koncentriranih varijabli. Rezultati na temelju odabira 4 ili 3 klastera pokazali su da jadranska i kontinentalna hrvatska ne spadaju u isti klaster. Od 4 klastera, jadranska hrvatska je smještena u drugi klaster, skupa sa ostalih 37 regija a kontinentalna hrvatska u treći skupa sa ostalih 30 regija. Regije s kojima su pronađene sličnosti u pogledu strukturnih uvjeta su uglavnom mediteranske regije i regije istočne europa. Dakle i ovom klaster analizom je utvrđeno da regije jadranska i kontinentalna hrvatska nisu dovoljno slične da bi se mogle okarakterizirati kao homogene.

Dakle podatci hijerarhijske klaster analize nam govore da iako su jadranska i kontinentalna hrvatska prvi upareni u klaster, a to se može vidjeti i po matrici udaljenosti, da nisu po strukturnim karakteristikama toliko slične jedna drugoj. Odnosno sa koeficijentom različitosti od 583,982 one jesu najbližije jedna drugoj ali postoji mnogo više regija koje su bližije po strukturnim karakteristikama.

Treba napomenuti i mane klaster analiza a to su da izostaje statističke osnove i da se zaključci donose na temelju subjektivne procjene analitičara. Isto tako rezultati same analize ovise o primjeri različitih vrsta klaster analizi i odabirom metoda čime se može manipulirati rezultatima. Isto tako krajnji rezultat ovisi uvelike o varijablama koje su korištene te o broju klastera koji istraživač može odrediti po svojoj procjeni (Devčić i dr., 2012).

Slika 5: Moguća struktura regija po jednakim strukturnim uvjetima u klastere

Izvor : Navarro et. al (2014)

Također i Navarro et.al. u svom radu upozorava na moguće greške prilikom sastavljanja referentnih regija. Primjer sa slike upućuje na regiju X koja spada u klaster G1 a zapravo je puno bliži području klastera G3. Stoga se prilikom analiziranja rezultata treba i to uzeti u obzir.

6. ZAKLJUČAK

Svjetska gospodarska kriza ostavlja je veliki trag za sobom i njezine posljedice mogle su se osjetiti još godinama poslije. Nekim zemljama oporavak je trajao puno duže i općenito je kriza imala manji utjecaj na njima u odnosu na druge zemlje. Analiziranjem struktura tih zemalja se može vidjeti da imaju puno razvijeniju istraživačko inovacijsku strukturu i razvijeniji ICT. Također je uviđeno da europa u odnosu na ostale svjetske velesile znatno zaostaje za ova dva segmenta. Kako je lisabonska strategija bila pri kraju a nova strategija pred vratima bila je to prilika da se odrede svježiji ciljevi sa dostatnim financijskim ulaganjima za borbu protiv krize a i ispravljanje strukturnih slabosti Europske unije. Nova europska strategija teži ostvarenju pametnog, održivog i uključivog rasta. Gdje se za pametan rast glavni fokus stavlja na ulaganje u I&R koji se najmerava ostvari Europskim fondom za regionalni razvoj u sklopu kohezijske politike. Da bi zemlje članice povukle sredstva za jačanje I&R i ulaganje u ICT potrebno je ispuniti preduvjet donošenj strategije pametne specijalizacije.

Strategija pametne specijalizacije RH donešena je 2016. godine, njome su određeni ciljevi, te tematska prioritetna područja po horizontalnim temama. Dok zemlje članice imaju pravo same birati na kojoj razini će se strategija usvojiti, neke svjetske organizacije savjetuju usvajanje strategije na NUTS II razini. Neki od autora također naglašavaju sve veću važnost regija u konkurentskom natjecanju i privlačenju investicija. Postavlja se pitanje dali su na temelju toga regije jadranske i kontinentalne hrvatske u dovoljnoj mjeri konkurentne za provođenje strategije pametne specijalizacije na nacionalnoj razini i dali postoje druge regije europske unije koje su po svojim strukturnim karakteristikama sličnije regijama hrvatske. Prije provođenja istraživanja bilo je potrebno pronaći varijable za definiranje homogenosti regije, pomoću varijabli odrđenih od autora Navarra, M. i dr. (2014). Nakon toga varijable su podvrgnute hijerarhijskoj i nehijerarhijskoj klaster analizi. Hijerarhijska klaster analiza pokazuje da regije nisu u tolikoj mjeri povezane jedna s drugom, odnosno da su više povezane međusobno nego s bilo kojim drugim regijama. Individualnim pristupom na matrici udaljenosti se također vidi da su jadranska i kontinentalna hrvatska najbliže jedna drugoj ali s obzirom na koeficijent povezanosti, nisu u tolikoj mjeri povezane da bi se mogle definirati kao homogene. Nehijerarhijskom klaster analizom, jadranska i kontinentalna hrvatska nisu smješte u isti klaster što također potvrđuje i rezultate prve analize.

LITERATURA

KNJIGE

1. Kersan-Škabić, I. (2012). *Ekonomija Europske Unije*. Sveučilište Jurja Dobrile u Puli
2. Renko N., Delić S., Škrtić M. (1999.) *Benchmarking u strategiji marketinga*. MATE d.o.o. Zagreb
3. Savić, Z. (2015). *Kohezijska politika Europske Unije i Hrvatska: 2014.-2020.: vodić kroz strateški okvir i pregled mogućnosti financiranja*. Zagreb: Hrvatska gospodarska komora.

ČASOPISI, STUDIJE I INTERNET IZVORI

1. BAK Basel Economics (2009). *Assembly of european regions*. [online]. Dostupno na: <https://aer.eu/subsidiarity-success-impact-decentralisation-economic-growth/>
2. Charron et.al (2012). *Regional Governance Matters* [online]. Dostupno na: http://ec.europa.eu/regional_policy/sources/docgener/work/2012_02_governance.pdf bbb
3. Council of the European Union (2013). *Council adopts the multiannual financial framework 2014-2020* [online]. Dostupno na: http://www.consilium.europa.eu/uedocs/cms_data/docs/pressdata/en/ecofin/139831.pdf
4. European Commission (2010). *Europa 2020. Europska strategija za pametan, održiv i uključiv rast* [online]. Dostupno na : <http://eur-lex.europa.eu/LexUriServ/LexUriServ.do?uri=COM:2010:2020:FIN:EN:PDF>
5. European Commission (2010 b). *Lisbon strategy evaluation document* [online]. Dostupno na: <http://ec.europa.eu/transparency/regdoc/rep/2/2010/EN/SEC-2010-114-F1-EN-MAIN-PART-1.PDF>
6. European Commission (2012b). *The European Union Explained: Europe 2020: Europe's growth strategy* [online]. Dostupno na: <http://www.renatosoru.eu/wp-content/uploads/2015/02/Europe-2020.pdf>

7. Europska komisija/Europska Unija (2013a). *Innovation Union; A pocket guide on a Europe 2020 strategy* [online]. Dostupno na: Luxembourg: Publications office of the European Union
8. Europska komisija (2013b). The role of clusters in smart specialization strategy. [online]. Dostupno na: https://ec.europa.eu/research/evaluations/pdf/archive/other_reports_studies_and_documents/clusters_smart_spec2013.pdf
9. Europska komisija (2014a). *Financijski instrumenti u kohezijskoj politici za razdoblje 2014.-2020.* [online]. Dostupno na: http://ec.europa.eu/regional_policy/sources/docgener/informat/2014/financial_instruments_hr.pdf
10. Europska komisija (2014b). *Horizon 2020: The EU Framework Programme for Research & Innovation* [online]. Dostupno na: Luxembourg: Publications office of the European Union.
11. Europska komisija (2014c). *Nacionalne/regionalne inovacijske strategije za pametnu specijalizaciju (RIS3)*, [online]. Dostupno na: http://ec.europa.eu/regional_policy/sources/docgener/informat/2014/smart_specialisation_hr.pdf
12. Panorama inforegio (2014). *Kohezijska politika 2014.-2020.* [online]. Dostupno na: http://ec.europa.eu/regional_policy/sources/docgener/panorama/pdf/mag48/mag48_hr.pdf
13. Europska komisija (2014e). *Politike Europske Unije: Regionalna Politika* [online]. Dostupno na: http://europa.eu/pol/pdf/flipbook/hr/regional_policy_hr.pdf
14. Europska komisija (2014f). *EU Cohesion policy 20014-2020, Targetin Investments on Key Growth Priorities*, [online]. Dostupno na: http://ec.europa.eu/regional_policy/sources/docgener/informat/2014/fiche_innovation_en.pdf

15. Europska komisija (2014g). *Ulaganja u radna mjesta i rast. Promicanje razvoja i dobrog upravljanja u regijama i gradovima EU-a, Šesto izvješće o gospodarskoj, socijalnoj i teritorijalnoj koheziji*, [online]. Dostupno na: http://ec.europa.eu/regional_policy/sources/docoffic/official/reports/cohesion6/6cr_hr.pdf
16. Europska komisija (2015). *Europski strukturni i investicijski fondovi za razdoblje 2014. do 2020.* [online]. Dostupno na: http://ec.europa.eu/regional_policy/sources/docgener/guides/blue_book/blueguide_hr.pdf
17. Europska komisija (2016). *JRC Techniocal Report. How Outward – looking is Smart Specialisation?*, [online]. Dostupno na: <http://s3platform.jrc.ec.europa.eu/documents/20182/154989/How+outward+looking+is+Smart+Specialisation/1f0813c2-901c-487c-bdf6->
18. Eurostat (2015). *Eurostat regional yearbook 2015.* [online]. Dostupno na: <http://ec.europa.eu/eurostat/documents/3217494/7018888/KS-HA-15-001-EN-N.pdf/6f0d4095-5e7a-4aab-af28-d255e2bcb395>
19. Foray, D. *Innovation For Growth – i4g, Smart specialisation and the New Industrial Policy agenda. Policy Brief No8.* [online]. Dostupno na: https://ec.europa.eu/research/innovation-union/pdf/expert-groups/i4g-reports/i4g_policy_brief_8_-_smart_specialisation.pdf
20. Foray, D. i dr. (2012). *Guide to Research and Innovation Strategies for Smart Specialisation (RIS3).* [online]. Dostupno na: http://ec.europa.eu/regional_policy/sources/docgener/presenta/smart_specialisation/smart_ris3_2012.pdf
21. Huggins, R i dr. (2013). *Regional Competitiveness: Theories and Methodologies for Empirical Analysis* [online]. Dostupno na: https://papers.ssrn.com/sol3/papers.cfm?abstract_id=2332832
22. MINGO (2014a). *Industrijska strategija RH 2014. – 2020.* [online]. Dostupno na: https://www.mingo.hr/public/industrija/Industrijska_strategija_%202014_2020.pdf

23. MINGO (2014b). Strategija poticanja inovacija RH 2014. – 2020. [online]. Dostupno na: https://www.mingo.hr/public/documents/Strategija_poticanja_inovacija_18_12_14.pdf
24. MINGO (2014). *Operativni program Konkurentnost i kohezija 2014.-2020.* [online]. Dostupno na: http://www.mingo.hr/public/investicije/OPKK_2014_2020_31316.pdf
25. Narodne novine (2012). *Nacionalna klasifikacija prostornih jedinica za statistiku 2012.* Zagreb: Narodne Novine d.d., 103/03., 75/09. i 52/12. str. 2161 [online]. Dostupno na: http://narodne-novine.nn.hr/clanci/sluzbeni/2012_08_96_2161.html
26. Narodne novine, (2016). *Strategija pametne specijalizacije Republike Hrvatske za razdoblje od 2016.-2020. godine i akcijski plan za provedbu strategije pametne specijalizacije Republike Hrvatske za razdoblje od 2016. Do 2017. Godine.* Zagreb: Narodne Novine d.d., 32, str. 2-127 [online]. Dostupno na: <http://narodne-novine.nn.hr/clanci/sluzbeni/dodatni/439965.pdf>
27. Navarro, M. et al. (2014). *Regional benchmarking in the smart specialisation process: Identification of reference regions based on structural similarity*, [online]. Dostupno na: http://s3platform.jrc.ec.europa.eu/documents/20182/114903/JRC89819_RegionalBenchmarking.pdf/699a6115-f685-4567-969d-921d116a304e
28. OECD, (2013). *Innovation driven Growth in Regions: The Role of smart Specialisation*, [online]. Dostupno na: <https://www.oecd.org/innovation/inno/smart-specialisation.pdf>.
29. Vlada RH (2013). Strategija razvoja turizma RH do 2020. Godine. [online]. Dostupno na <https://mint.gov.hr/UserDocsImages/arhiva/130426-Strategija-turizam-2020.pdf>

INTERNETSKE STRANICE:

1. http://appsso.eurostat.ec.europa.eu/nui/show.do?dataset=lfst_r_lfe2en2&lang=en
2. http://appsso.eurostat.ec.europa.eu/nui/show.do?dataset=nama_10r_2gdp&lang=en
3. http://appsso.eurostat.ec.europa.eu/nui/show.do?dataset=sbs_r_nuts06_r2&lang=en
4. <https://www.bak-economics.com/ueber-uns/>

5. <https://www.dziv.hr/hr/intelektualno-vlasnistvo/patenti/medunarodna-zastita/medunarodna-prijava-patenta/>
6. http://www.europeansocialsurvey.org/download.html?file=ESS5e03_3&c=&y=2010&logged_in
7. <http://www.europeansocialsurvey.org/data/>
8. <https://www.fina.hr/Default.aspx?art=11342>
9. <https://nicholascharron.wordpress.com/european-quality-of-government-index-eqi/>
10. <https://stats.oecd.org/>
11. https://www.oecd-ilibrary.org/docserver/reg_glance-2013-47_en.pdf?expires=1537335188&id=id&accname=guest&checksum=633A43AA4722782880C7CD5F6D337927

PRILOZI

Tablica 13: Određivanje faktora vrijednosti 21 koncentrirane varijable

	Kodovi koncentriranih varijabli	Faktor vrijednosti (22 varijable)*	Faktor vrijednosti (21 varijabla)**
1	Zdem.pop.avg	5,23%	5,52%
2	dob.prosjek	3,89%	4,10%
3	Zdem.pop.urban	4,75%	5,01%
4	Zobrazovanje	4,00%	4,22%
5	pat.f.a.01	3,49%	3,68%
6	pat.f.a.02	5,72%	6,03%
7	pat.f.a.03	3,75%	3,96%
8	Zpat.gini.05	5,05%	5,33%
9	zap.ukupno.f.a.01	5,43%	5,73%
10	zap.ukupno.f.a.02	5,02%	5,30%
11	zap.ukupno.f.a.03	4,23%	4,46%
12	zap.ind.f.a.01	5,07%	5,35%
13	zap.ind.f.a.02	4,28%	4,51%
14	zap.ind.f.a.03	4,30%	4,54%
15	zap.ind.f.a.04	4,57%	4,82%
16	Zzap.top5	5,29%	5,58%
17	Zpod.vel.prosjek	3,93%	4,15%
18	Zizvoz.bdp.posto	5,01%	5,29%
19	Zinst.decentr	3,99%	4,21%
20	soc.inst.kap.f.a.01	5,45%	5,75%
21	pod.inov.stav.prosjek	2,06%	2,17%
	Σ	94,51%	99,70%

Izvor: *Navarro M. i dr. (2014); ** Izračun autora

Tablica 14: Vrijednosti definiranih varijabli za jadransku i kontinentalnu hrvatsku

DIMENZIJA	VARIJABLE	JADRANSKA	KONTINENTALNA	DIMENZIJA	VARIJABLE	JADRANSKA	KONTINENTALNA
1. Geo - demografski	Ukupna populacija	1 413 426	2 876 431	Sektorska koncentracija	Top 5 podsektora (2jedinice) (% ukupne zaposlenosti)	28.09%	21.59%
	Populacija >=65	18.32%	17.44%		Rudarstvo i vađenje (05-09)	6.04%	4.89%
	Populacija <15	14.80%	15.50%		Hrana, piće, duhan (10-12)	25.08%	22.76%
	Populacija u urbanim i dnevnim migracijskim zonama	55.73%	53.79%		Tekstil, odjeća i koža (13-15)	4.38%	14.13%
2. Razina obrazovanja	Populacija sa višim srednjim i terciarnim obrazovanjem	85.2	78.1	4. Industrijska sektorska struktura	Drvo, papir i tisak (16-18)	7.58%	11.72%
3. Tehnološka specijalizacija	Biotehnologija	19.35%	13.01%		Kemija, Farmacija, guma, plastika i rafinirana nafta (19-22)	6.34%	8.49%
	ICT	23.39%	44.89%		Ne metalni, mineralni proizvodi (23)	6.77%	3.76%
	Nanotehnologija	0.00%	0.00%		Osnovni metali i metalni proizvodi (24-25)	14.22%	12.46%
	Medicinska tehnologija	33.87%	1.76%		Električna, elektronska, kompjuterska i optička oprema (26-27)	2.80%	6.98%
	Farmacija	23.39%	40.34%		Mašinerija (28)	2.48%	4.89%
	Gini indeks od 35 podpodručja	0.29	0.51		Transportna oprema (29-30)	11.41%	1.62%
4. Ekonomska sektorska distribucija	Poljoprivreda, šumarstvo i ribolov (A)	6.69%	14.86%	5. Veličina poduzeća	Prosječna veličina poduzeća	5.8	9.7
	Industrija (osim građ.) (B-E)	18.71%	21.96%	6. Otvorenost	Ukupan izvoz (%BDP-a)	16.83%	20.80%
	Građevinarstvo (F)	6.25%	7.30%	7. Višedimenzijaska država	Decentralizacija	38	38
	Trgovina na veliko i malo, transport i sl. (B-I)	35.15%	22.76%	7. Socijalni i institucionalni kapital	Kvaliteta institucija	-1.28	-1.13
	Informacije i komunikacije (J)	1.61%	2.64%		Osjećaj sigurnosti hodanja sam u lokalnom području po mraku	1.76	1.74
	Financijske i osiguravajuće aktivnosti (K)	2.68%	2.44%		Većini ljudi se može vjerovati ili nikad ne možeš biti pre siguran	4.27	4.55
	Nekretnine (L)	0.36%	0.13%	7. Poduzetničko / inovativni stav	Važno je smišljati nove ideje i biti kreativan	2.84	2.85
	Profesionalne, znanstvene i tehničke aktivnosti (M-N)	5.88%	5.90%		Važno je probati nove i drugačije stvari u životu	3.66	3.24
	Javna administracija (O-Q)	18.45%	18.02%				
	Umjestnost, zabava i rekreacija (R-U)	4.11%	3.81%				

Izvor: Izračuna autora na temelju definiranih varijabli Navarra, M. i dr. (2014)

POPIS TABLICA

Tablica 1: Varijable za određivanje regija jednakih strukturnih karakteristika	30
Tablica 2: Distribucija patenata jadranske i kontinentalne hrvatske u periodu od 2009. - 2013.	32
Tablica 3: Gini index koncentracije patenata jadranske i kontinentalne regije	33
Tablica 4: Sektorska koncentracija zaposlenosti jadranske i kontinentalne hrvatske u 2014. godini	36
Tablica 5: "Osjećaj sigurnog kretanja samog po noći u susjedstvu" od 1 - 4 za jadransku i kontinentalnu hrvatsku	40
Tablica 6: "Većini ljudi se može vjerovati ili nikada ne možeš biti previše oprezan" od 0 - 10 za jadransku i kontinentalnu hrvatsku	41
Tablica 7: "Važno je smišljati nove ideje i biti kreativan" za jadransku i kontinentalnu regiju	42
Tablica 8: "Važno je isprobavati nove i različite stvari u životu" za jadransku i kontinentalnu hrvatsku	42
Tablica 9: Referentne regije jadranske i kontinentalne hrvatske odabrane na temelju individualnog pristupa	50
Tablica 10: Usporedba hrvatskih regija s referentnim regijama u geo demografskoj, obrazovnoj i tehnološkoj dimenziji	51
Tablica 11: Usporedba hrvatskih regija s referentnim regijama u sektorskoj dimenziji	52
Tablica 12: Usporedba hrvatskih regija s referentnim regijama u dimenzijama veličine poduzeća, otvorenosti, decentralizacije te institucionalnih i poduzetničkih vrijednosti	53
Tablica 13: Određivanje faktora vrijednosti 21 koncentrirane varijable	62
Tablica 14: Vrijednosti definiranih varijabli za jadransku i kontinentalnu hrvatsku	63

POPIS SLIKA

Slika 1: Strategija pametne specijalizacije kao dio gospodarske strategije	21
Slika 2: Lorenzova krivulja distribucije patenata jadranske i kontinentalne hrvatske	34
Slika 3: Pod - indikatori decentralizacije za RH u 2009. godini	38
Slika 4: Dendrogram dobiven hijerarhijskom klaster analizom u SPSS-u	49

SAŽETAK

Strategija pametne specijalizacije u vrlo kratkome je roku dobila na važnost. To je bio odgovor na strukturne probleme uviđene na europskom teritoriju. Ubrzo je postala jedan od preduvjeta za povlačenje značajnih financijskih sredstava iz Europskog fonda za regionalni razvoj. S obzirom na njezinu važnost bitno je uspostaviti dobro definiranu strategiju kako bi se povećala ulaganja u ključna područja i time utjecalo na strukturu same ekonomije i ostvarenje dugoročnog rasta. Strategija je za hrvatsku donesena na nacionalnu razinu koja možda i nije najbolji izbor s obzirom na sumnju u različitost te dvije regije. Empirijsko istraživanje dokazuje da iako su jadranska i kontinentalna hrvatska najsličnije regije jedna drugoj da ipak nisu u tolikoj mjeri slične da bi se mogle okarakterizirati kao homogene i podložne za provođenje jedne strategije.

Ključne riječi: Strategija Pametne specijalizacije, inovacije, I&R, homogenost regija

SUMMARY

The Research and Innovation Strategy for Smart Specialisation gained importance in a very short time. This was the answer to the structural problems encountered in the European territory. It soon became one of the prerequisites for the withdrawal of significant financial resources from the European Regional Development Fund. Given its importance, it is essential to establish a well-defined strategy to increase investment in key areas and thus affect the structure of the economy itself and the achievement of long-term growth. The strategy for Croatia has been brought at the national level, which may not be the best due to the doubt about the diversity of the two regions. Empirical research shows this and proves that although the “Jadranska” and “Kontinentalna” Croatian regions are the most similar in the region, they are not so similar that they can be characterized as homogeneous and subject to the implementation of one unique strategy for two different regions.

KEY WORDS: Smart specialisation strategy, innovation, R&D, homogenous regions